



# FACULTAD DE INGENIERÍA

**CARRERA DE INGENIERIA INDUSTRIAL**

**“METODOLOGÍA DE SIMULACIÓN CON  
INTELIGENCIA ARTIFICIAL EN LA  
PLANIFICACIÓN Y CONTROL DE LA  
PRODUCCIÓN, EN SISTEMAS DE MANUFACTURA  
DE FUNDICIÓN”**

Tesis para optar el título profesional de:

**Ingeniero Industrial**

Autor:

Percy Marcial Romero Ríos

Asesor:

Dr. Ing. Durand Porras Juan Carlos

Lima - Perú

2021

## **DEDICATORIA**

A mis padres y hermanos quienes han sido parte fundamental para desarrollar este trabajo de investigación, ellos son los que me dieron grandes lecciones de vida y son los protagonistas de este logro alcanzado, también a todas las personas que han apoyado en la realización de esta tesis.

## **AGRADECIMIENTO**

Son muchas las personas que han contribuido al proceso y culminación de este trabajo de investigación. En primer lugar, agradezco a mis padres doña Luisa y don Tito, a mis hermanos por su apoyo y motivación, a los profesores de la universidad, al asesor Ingeniero Juan Carlos Durand Porras por su tiempo dedicado y continuo apoyo en los momentos difíciles durante el desarrollo de este trabajo de investigación, al gerente de la empresa en estudio y a los amigos que apoyaron en este trabajo. Sinceramente fueron una parte importante para la culminación de este trabajo lo cual estaré agradecido por siempre.

## Tabla de contenidos

<b>DEDICATORIA .....</b>	<b>2</b>
<b>AGRADECIMIENTO.....</b>	<b>3</b>
<b>ÍNDICE DE TABLAS .....</b>	<b>6</b>
<b>ÍNDICE DE FIGURAS .....</b>	<b>7</b>
<b>ÍNDICE DE ECUACIONES .....</b>	<b>8</b>
<b>RESUMEN .....</b>	<b>9</b>
<b>ABSTRACT .....</b>	<b>10</b>
<b>CAPÍTULO I. INTRODUCCIÓN .....</b>	<b>11</b>
<b>1.1. Realidad Problemática.....</b>	<b>11</b>
<b>1.1.1. Delimitación de la Investigación – Descripción de la Empresa.....</b>	<b>11</b>
<b>1.1.2. Realidad problemática a nivel internacional y nacional.....</b>	<b>13</b>
<b>1.1.3. Realidad Problemática a nivel local (institucional).....</b>	<b>14</b>
<b>1.2. Formulación del Problema .....</b>	<b>17</b>
<b>1.2.1. Problema General .....</b>	<b>17</b>
<b>1.2.2. Problemas Específicos.....</b>	<b>17</b>
<b>1.3. Objetivos de la investigación .....</b>	<b>18</b>
<b>1.3.1. Objetivo General .....</b>	<b>18</b>
<b>1.3.2. Objetivos Específicos.....</b>	<b>18</b>
<b>1.4. Hipótesis de la investigación.....</b>	<b>19</b>
<b>1.4.1. Hipótesis General .....</b>	<b>19</b>
<b>1.4.2. Hipótesis Específicos .....</b>	<b>19</b>
<b>1.5. Justificación de la investigación .....</b>	<b>19</b>
<b>1.5.1. Justificación Teórica .....</b>	<b>19</b>
<b>1.5.2. Justificación Practica .....</b>	<b>20</b>

<b>1.5.3. Justificación Cuantitativa.....</b>	<b>21</b>
<b>1.5.4. Justificación Social.....</b>	<b>21</b>
<b>CAPÍTULO II. MARCO TEÓRICO .....</b>	<b>22</b>
<b>2.1. Antecedentes de la investigación .....</b>	<b>22</b>
<b>2.1.1. Antecedentes internacionales.....</b>	<b>22</b>
<b>2.1.1. Antecedentes nacionales.....</b>	<b>23</b>
<b>2.2. Bases Teóricas.....</b>	<b>26</b>
<b>2.3. Definición de términos básicos .....</b>	<b>51</b>
<b>CAPÍTULO III. METODOLOGIA.....</b>	<b>54</b>
<b>3.1. Tipo de Investigación .....</b>	<b>54</b>
<b>3.2. Técnicas e instrumentos de recolección y análisis de datos .....</b>	<b>55</b>
<b>3.3. Procedimientos para el desarrollo de la investigación .....</b>	<b>58</b>
<b>CAPÍTULO IV. RESULTADOS .....</b>	<b>61</b>
<b>4.1. Desarrollo el objetivo específico 1 .....</b>	<b>61</b>
<b>4.2. Desarrollo el objetivo específico 2 .....</b>	<b>74</b>
<b>4.3. Desarrollo el objetivo específico 3 .....</b>	<b>81</b>
<b>4.4. Desarrollo el objetivo específico 4 .....</b>	<b>83</b>
<b>4.5. Desarrollo el objetivo General.....</b>	<b>85</b>
<b>CAPÍTULO V. DISCUSIÓN Y CONCLUSIONES .....</b>	<b>87</b>
<b>5.1. Discusión de resultados .....</b>	<b>87</b>
<b>5.2. Conclusiones.....</b>	<b>89</b>
<b>5.3. Recomendaciones.....</b>	<b>90</b>
<b>REFERENCIAS .....</b>	<b>91</b>
<b>ANEXOS .....</b>	<b>95</b>

## ÍNDICE DE TABLAS

Tabla 1 <i>Tiempos de parada generados por los equipos que integran la línea A120 trefiladora</i>	17
Tabla 2 <i>Comparativo del perceptrón con las demás RNAs</i>	34
Tabla 3 <i>Usos prácticos de las RNAs</i>	36
Tabla 4 <i>Pasos para el pronóstico del costo de parada de línea mediante RNA</i>	62
Tabla 5 <i>Entrenamiento de la RNAs</i>	63
Tabla 6 <i>Comparativo de los ECM de las configuraciones de las RNAs</i>	67
Tabla 7 <i>Valores de costo de parada de línea pronosticado en <math>Y_i</math></i>	68
Tabla 8 <i>Valores de las variables de producción en la línea</i>	69
Tabla 9 <i>Valores obtenidos para el costo de parada de línea según la ecuación</i>	70
Tabla 10 <i>Costos de parada de línea para los meses en estudio</i>	70
Tabla 11 <i>Comparación de método del experto y de la RNA para los costos de parada de línea</i>	72
Tabla 12 <i>Variables de la producción de la línea A120</i>	74
Tabla 13 <i>Horas calculadas con los datos del pronosticadas mediante la RNA</i>	75
Tabla 14 <i>Plan de capacitación de los operadores de la línea</i>	77
Tabla 15 <i>Plan del mantenimiento anterior</i>	77
Tabla 16 <i>Variables de producción de la línea</i>	78
Tabla 17 <i>Eficiencia General de los Equipos (OEE) de los meses en estudio</i>	79
Tabla 18 <i>Propuesta de plan de mantenimiento</i>	80
Tabla 19 <i>Disminución del tiempo de parada aplicando el plan de mantenimiento</i>	80
Tabla 20 <i>Variables de producción de la línea</i>	81
Tabla 21 <i>Horas de parada de línea obtenidas del pronostico</i>	81
Tabla 22 <i>Aumento de la producción aplicando el plan de mantenimiento</i>	82
Tabla 23 <i>Costos de parada de línea de la trefiladora por el pronóstico</i>	83
Tabla 24 <i>Montos recuperados después reducir los tiempos de parada</i>	84
Tabla 25 <i>Valores obtenidos en los objetivos específicos</i>	85

## **ÍNDICE DE FIGURAS**

<i>Figura 1.</i> Simulación del planeamiento y control de la producción. ....	11
<i>Figura 2.</i> Máquinas de una Línea Trefiladora.....	12
<i>Figura 3.</i> Diagrama de Pareto que muestra las horas de parada de las líneas de producción .....	15
<i>Figura 4.</i> Línea A120 que lo componen diferentes equipos .....	16
<i>Figura 5.</i> Diagrama de Ishikawa que identifica los problemas de la línea A120. ....	16
<i>Figura 6.</i> Representación de una red neuronal artificial .....	28
<i>Figura 7.</i> Taxonomía de las RNA según algunos de sus parámetros.....	29
<i>Figura 8.</i> Estructura de una red neuronal monocapa.....	30
<i>Figura 9.</i> Estructura de una red neuronales multicapa.....	30
<i>Figura 10.</i> Estructura de una red neuronal recurrente.....	31
<i>Figura 11.</i> Estructura del perceptrón multicapa.....	33
<i>Figura 12.</i> Flujo general de las actividades de planificación y control.....	37
<i>Figura 13.</i> Estructura las etapas de una línea de producción .....	39
<i>Figura 14.</i> Herramienta NNtool para el diseño de las RNA .....	42
<i>Figura 15.</i> Línea trefiladora de hilos de cobre .....	46
<i>Figura 16.</i> Estructura del diagrama de Pareto .....	47
<i>Figura 17.</i> Diagrama de causa efecto o de espina de pez.....	48
<i>Figura 18.</i> Simulación con los datos de validación para la red Simulacion_CP_05 .....	65
<i>Figura 19.</i> Errores de la validación Simulacion_CP_05.....	65
<i>Figura 20.</i> Resultados de los ECM de las RNAs. ....	66
<i>Figura 21.</i> RNA seleccionada para el pronóstico del costo de parada de línea A120 .....	67

## ÍNDICE DE ECUACIONES

<i>Ecuación 1. Productividad (P)</i> .....	40
<i>Ecuación 2. Cantidad demandada (Q)</i> .....	43
<i>Ecuación 3. Normalización de datos (Dn)</i> .....	48
<i>Ecuación 4. Error cuadrático medio (ECM)</i> .....	49
<i>Ecuación 5. Cantidad prevista por el experto (CPi)</i> .....	49
<i>Ecuación 6. Tasa de error medio de la RNA (EC)</i> .....	65
<i>Ecuación 7. Rendimiento de la RNA (CPi)</i> .....	69
<i>Ecuación 8. Costo de las horas de parada de línea (CP)</i> .....	69
<i>Ecuación 9. Horas de parada de línea (HPL)</i> .....	74
<i>Ecuación 10. Disponibilidad</i> .....	78
<i>Ecuación 11. Rendimiento</i> .....	78
<i>Ecuación 12. Tasa de calidad</i> .....	79
<i>Ecuación 13. Eficiencia general de equipo (OEE)</i> .....	79



## RESUMEN

El estudio realizado bajo la modalidad de tesis tuvo como objetivo general determinar cómo una metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Dicha metodología utiliza las redes neuronales artificiales (RNA) para pronosticar los costos de parada de la línea trefiladora del área de producción, se eligió esta metodología para dar respuesta a un problema de la empresa, en la que se detectó altas paradas de la línea trefiladora. Para el diagnóstico del problema se recurrió a él diagrama de Ishikawa y diagrama de Pareto, identificando en la línea los equipos que generan horas altas de parada, para luego proceder a la aplicación de una metodología basado en Redes Neuronales Artificiales en el pronóstico del costo de parada. Se utilizó la herramienta Neural Net Works de Matlab para la fase de topología, configuración, aprendizaje, entrenamiento y pronóstico basados en la RNA Perceptrón Multicapa.

Los resultados de la investigación permitieron determinar el resultado de pronóstico del costo de parada, con un error de la RNA de 13.86%, que es menor obtenido por el experto que fue de 37.08% con respecto a los montos reales. Con los tiempos de parada de línea obtenidos a través del pronóstico en los meses de marzo, abril, mayo y junio del 2019, se propone un plan de mantenimiento autónomo que reduzca en un 30% los tiempos de parada de la línea, lo cual aumentaría la producción en marzo, en 6.327tn, para abril en 2.595tn, para mayo en 3.105tn y para junio en 5.842tn, generando ingresos adicionales en marzo con un monto de S/17,112.15, en abril de S/7,024.99, en mayo de S/8,398.46 y en junio de S/15,783.71 del 2019, los cuales suman un ingreso total de S/48,319.31.

**Palabras clave:** Redes Neuronales Artificiales, Aprendizaje, Pronóstico, Validación, Perceptrón, PCP, Producción, Rentabilidad, Tiempo de parada, Costo de parada de línea.

**ABSTRACT**

The study carried out under the modality of the thesis had as a general objective to determine how a Simulation methodology with Artificial Intelligence allows to help in the Planning and Control of Production, in Foundry Manufacturing systems. This methodology uses artificial neural networks (ANN) to forecast the shutdown costs of the drawing line in the production area, this methodology was chosen to respond to a problem of the company, in which high stops of the drawing line were detected . For the diagnosis of the problem, the Ishikawa diagram and Pareto diagram were used, identifying on the line the equipment that generate high stop hours, and then proceed to the application of a methodology based on Artificial Neural Networks in the forecast of the cost of stop. The Neural Net Works tool from Matlab was used for the topology, configuration, learning, training and forecasting phase based on the Multilayer Perceptron RNA.

The results of the investigation allowed determining the forecast result of the shutdown cost, with an error of the ANN of 13.86%, which is lower than obtained by the expert, which was 37.08% with respect to the real amounts. With the line stop times obtained through the forecast in the months of March, April, May and June 2019, an autonomous maintenance plan is proposed that reduces line stop times by 30%, which would increase the production in March, in 6,327tn, for April in 2,595tn, for May in 3,105tn and for June in 5,842tn, generating additional income in March with an amount of S / 17,112.15, in April of S / 7,024.99, in May of S / 8,398.46 and in June of S / 15,783.71 of 2019, which add up to a total income of S / 48,319.31.

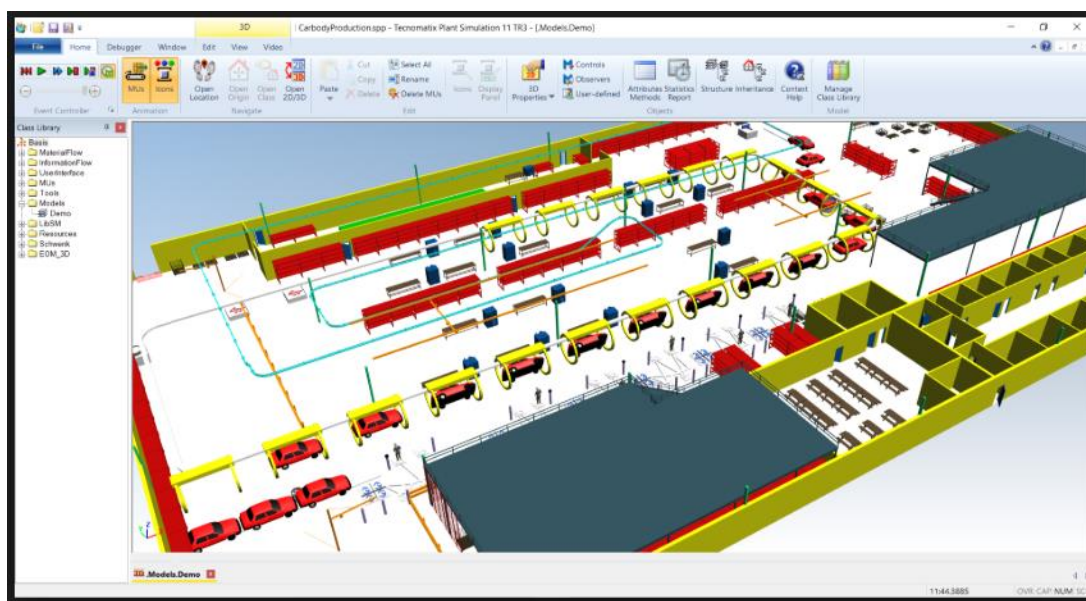
**Keywords:** Artificial Neural Networks, Learning, Forecast, Validation, Perceptron, PCP, Production, Profitability, Downtime, Line stoppage cost.

## **CAPÍTULO I. INTRODUCCIÓN**

### **1.1. Realidad Problemática**

#### **1.1.1. Delimitación de la Investigación – Descripción de la Empresa**

En la actualidad, el estudio de la planificación de la producción es de mayor importancia, ya que ha quedado demostrado que las empresas dedicadas al estudio sobre los métodos empleados en la gestión de la producción logran un mayor beneficio económico y una ventaja competitiva con el resto de la competencia.



**Figura 1.** Programa informático para la Simulación de la producción.

**Fuente:** Elaboración propia.

Se presenta una metodología de ayuda alternativa para la mejora del proceso de planeación de la producción, de manera transitoria. El principal problema es a menudo el tiempo para lograr una buena planeación, en relación al tiempo del que disponen las personas responsables de la producción. Este tiempo puede variar dependiendo de la magnitud de los problemas, de los equipos de cómputo disponibles en el área del planeamiento, etc. La información al respecto pone en evidencia un tiempo calculado elevado por el uso excesivo del simulador, en cuanto a la etapa de evaluación de los indicadores de producción. En este lineamiento y tomando en cuenta la complejidad del problema, se presenta un estudio basado en la combinación de la simulación y los métodos

de inteligencia artificial con algoritmos genéricos, los cuales han permitido obtener resultados satisfactorios para los problemas que se genera al realizar la planeación de la producción a corto plazo. (Buot y Henríquez,2001) afirman: La optimización de modelos de simulación puede ser definida como el proceso de ligar un método de optimización con un modelo de simulación para determinar los valores adecuados con ciertos parámetros de entrada de tal manera que maximice el desempeño del procedimiento simulado.

Mejora de la PCP en la línea de producción como en una línea trefiladora de una empresa de rubro de fundición, que nos permita aumentar el nivel de rendimiento, disponibilidad y confiabilidad operacional de las máquinas de tal forma que se conserven en condiciones de funcionamiento seguro y eficiente que garanticen la prestación de un servicio oportuno.



**Figura 2.** Máquinas de una Línea Trefiladora  
*Fuente:* Elaboración propia.

### 1.1.2. Realidad problemática a nivel internacional y nacional

#### a) A nivel internacional

Se observa que en los últimos años por los avances tecnológicos, organizacionales, económicos, sociales y humanos han surgido una gran cantidad de industrias en el que el factor competitivo y la calidad de los productos es de suma importancia, por consiguiente, generar mayores ganancias, las tareas de mantenimiento han evolucionado para tratar de evitar que las líneas de producción presenten mucho tiempo de parada.

Medir los tiempos, llegar a un estándar, es algo necesario para la gestión de la producción, pero aún no es suficiente. Todos los tiempos que tengamos en un listado de fabricación, no servirá para nada si no se controla la productividad y se realiza un seguimiento de cumplimiento (Cruelles, 2012)

las empresas manufactureras están utilizando la IA, por lo menos en una parte de la cadena de valor, ya sea en logística, fabricación o mantenimiento. En la fabricación, el rendimiento es el máximo indicador, por lo que se realiza muchas implementaciones de IA en el nivel de control del proceso, utilizando el aprendizaje automático para controlar mejor los procesos para la producción. Y sobre el tema del tiempo de inactividad, se implementa el aprendizaje automático para el mantenimiento predictivo, lo que facilita reemplazar los sistemas antes de que fallen y coordinar cualquier tiempo de inactividad, permitiendo ahorros y una disponibilidad mayor.

El desarrollo de algoritmos informáticos que logren que a las computadoras procesen datos a una velocidad insólito, logrando además aprendizaje automático. Los algoritmos se alimentan de datos y experiencias recientes que se van perfeccionando. En la industria, permite el desarrollo de modelos neuronales aplicados a procesar imágenes lo cual mejora la seguridad y el control de calidad, también la predicción de series temporales de consumo

de energía eléctrica, y permite el desarrollo de estrategias para controlar la gestión optimizando las estaciones de producción (Basco, Beliz, Coatz y Garnero, 2018)

#### **b) A nivel nacional**

La industria metalmecánica es muy importante en la estructura productiva de la economía nacional, al proveer de bienes de capital como las maquinaria, equipos e instalaciones, también aportando con artículos y suministros, para diversos sectores industriales como la minería, construcción, transporte, pesca, electricidad, el cual lo convierte a una actividad generadora de importantes conexiones productivos y de empleo.

la teoría de decisiones tiene su base en uso de la información, no es suficiente la información impresa, pues en el siglo XXI el dominio es de la información electrónica es determinante. La tecnología de información (TI) de una organización que consiste en el hardware, el software, las telecomunicaciones, las bases de datos y otras tecnologías de almacenamiento de datos, esa información almacenada tiene que estar disponibles para la toma de decisiones (Torres y Torres, 2014)

#### **1.1.3. Realidad Problemática a nivel local (institucional)**

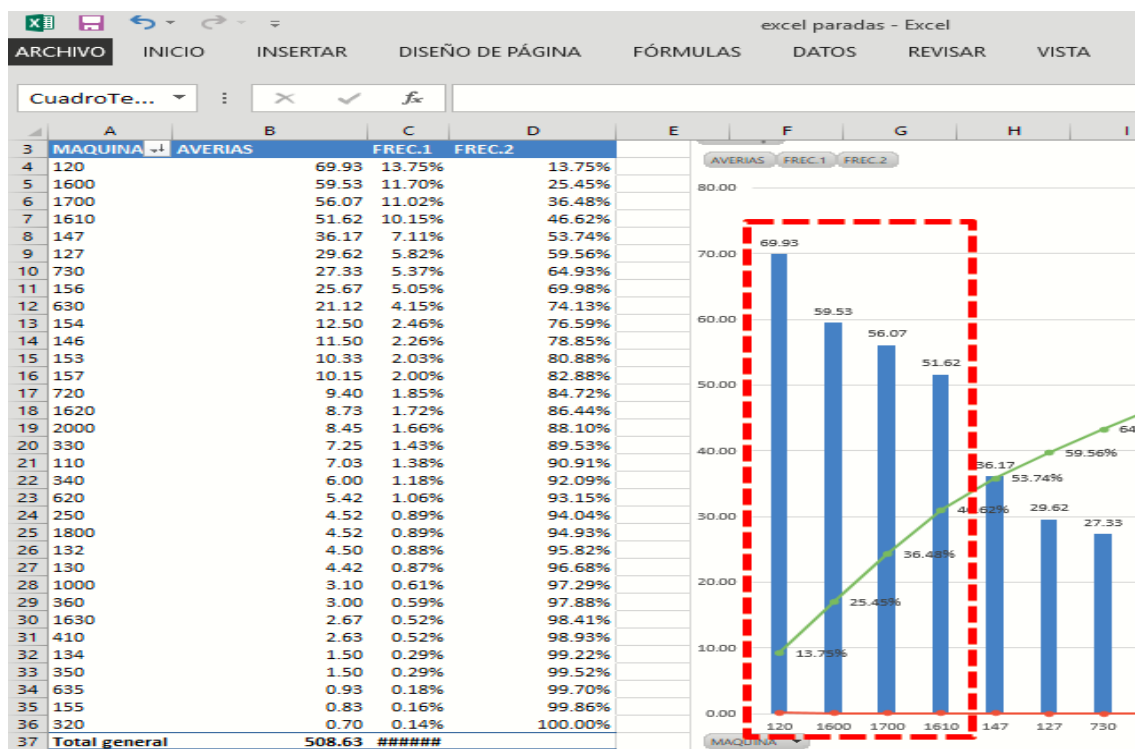
A nivel local en la empresa del rubro fundición, organización en la cual se llevó a cabo la investigación se detectó una serie de debilidades relacionadas con los costos de parada de la producción, productividad y tiempo de parada.

- a. En la actualidad la empresa, cuenta con un área de mantenimiento y este a la vez cuenta con un software en el cual se registra las paradas por fallas de las diferentes líneas, se tiene la información necesaria para el análisis, pero no se está trabajando bajo estándares sus procesos, por tal motivo la productividad es reducida por las paradas de las líneas de producción.



- b. Actualmente la empresa maneja el mantenimiento correctivo, puesto que las acciones que se toman son para reparar las fallas y arreglar la máquina. A menudo se presentan grandes fallas en las máquinas que obligan al operario a parar con la producción a realizar por varias horas, lo que genera pérdida de tiempo afectando directamente en el retraso en las fechas establecidas.
- c. Debido a la alta producción y horas recortadas para realizar mantenimientos, solo se realizan mantenimientos correctivos y mantenimientos programados en las horas de paradas de líneas siendo que los técnicos tienen trabajos en diferentes máquinas y no se realiza el adecuado mantenimiento para estos equipos.
- d. las paradas de las líneas generan que la producción se reduzca generando pérdidas.
- e. No se cuenta con un método de simulación que pueda pronosticar los posibles tiempos de parada.

A continuación, se muestra una figura 3. con las horas de parada de la línea trefiladora



**Figura 3.** Diagrama de Pareto que muestra las horas de parada de las líneas de producción

Fuente: Elaboración propia

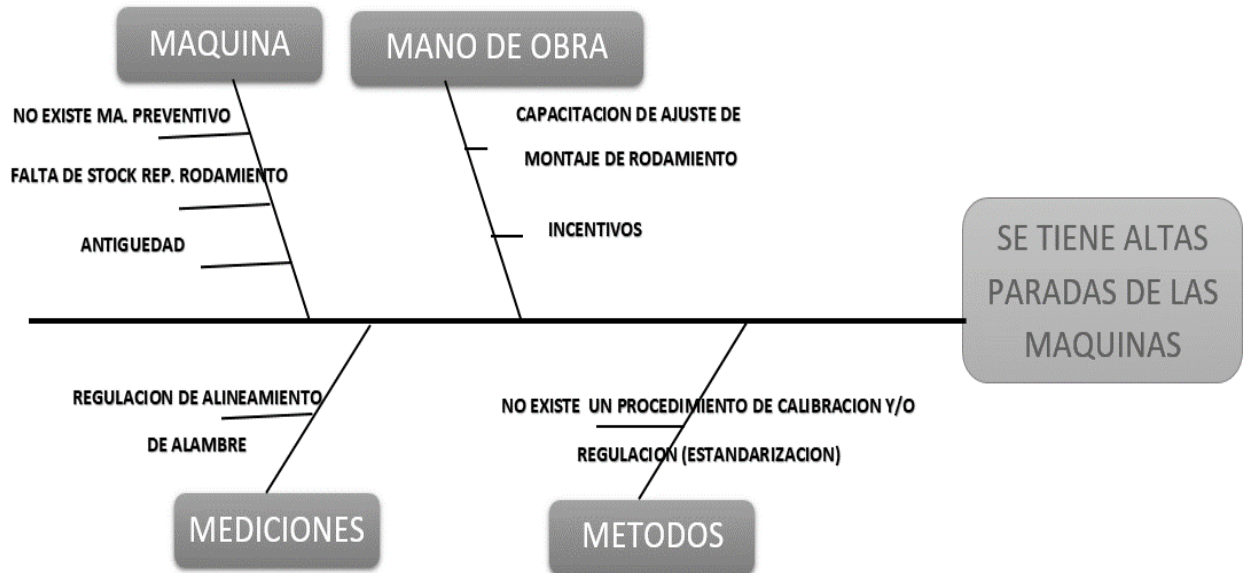
Se observa en la **figura 3**; las diferentes líneas de producción de la empresa de fundición, la línea A120 se refiere a la línea de trefilación muestra 69.3 horas de parada de línea.



**Figura 4.** Línea A120 que lo componen diferentes equipos

*Fuente:* Elaboración propia

Se observa en la **figura 4**; la línea A120 con sus diferentes etapas que son los equipos que la componen, esta línea trefiladora reduce el diámetro de los tubos de cobre a la medida estipulada en la programación.



**Figura 5.** Diagrama de Ishikawa que identifica los problemas de la línea A120.

*Fuente:* Elaboración propia.

Se observa en la **figura 5**; el diagrama Ishikawa muestra los problemas internos la trefiladora llamada A120 que genera altas paradas de la línea.



**Tabla 1**

*Tiempos de parada generados por los equipos que integran la línea A120 trefiladora*

Mes	N° mes	Polines guías de coiller(hrs)	Sistema eléctrico / cambio de motor(hrs)	Sistema mecánico coiller(hrs)	Sistema tran- mec giro plataforma(hrs)	Otras fallas(hrs)	Horas de parada(hrs)
Ene-2018	1	9.03	0.00	1.92	1.87	3.50	16.32
Feb-2018	2	1.18	0.00	4.23	0.00	0.00	5.42
Mar-2018	3	13.70	1.17	0.82	0.00	0.00	15.68
Abr-2018	4	1.67	0.00	4.80	0.00	0.00	6.47
May-2018	5	10.62	0.00	5.20	2.12	7.67	25.60
Jun-2018	6	13.15	1.08	0.25	0.00	0.00	14.48
Jul-2018	7	8.70	0.50	0.45	0.23	5.23	15.11
Ago-2018	8	2.50	0.80	0.90	1.56	4.56	10.32
Set-2018	9	10.05	1.20	2.30	0.25	6.80	20.60
Oct-2018	10	1.87	0.85	1.85	0.00	3.85	8.42
Nov-2018	11	8.50	0.60	0.30	1.70	0.00	11.10
Dic-2018	12	9.60	0.00	3.80	1.10	5.20	19.70
Ene-2019	1	7.20	0.30	2.10	0.00	5.26	14.86
Feb-2019	2	3.30	0.90	0.78	0.96	6.50	12.44
Mar-2019	3	11.50	1.30	4.52	1.56	4.23	23.11

*Nota:* El equipo polines guías de coiller genera más horas de parada.

## 1.2. Formulación del Problema

### 1.2.1. Problema General

¿Cómo una metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?

### 1.2.2. Problemas Específicos

- ¿Cómo una metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?
- ¿Cómo una metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?

- c. ¿Cómo una metodología de Simulación con Inteligencia Artificial ayuda a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?
- d. ¿Como una metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?

### **1.3. Objetivos de la investigación**

#### **1.3.1. Objetivo General**

Determinar cómo una metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

#### **1.3.2. Objetivos Específicos**

- a. Determinar cómo una metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- b. Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- c. Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- d. Determinar como una metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

## **1.4. Hipótesis de la investigación**

### **1.4.1. Hipótesis General**

Existe una mejora con una Metodología de Simulación con Inteligencia Artificial en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

### **1.4.2. Hipótesis Específicos**

- a. Existe una mejora con una metodología de Simulación con Inteligencia Artificial en el pronóstico de los costos de parada de línea, en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- b. Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a disminuir el tiempo de parada de línea, en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- c. Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.
- d. Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

## **1.5. Justificación de la investigación**

### **1.5.1. Justificación Teórica**

Desde el punto de vista teórico, la incorporación de la tecnología impulsa el crecimiento de las empresas, el uso de la inteligencia artificial para crear mejores procesos, productos y servicios. La inteligencia artificial está evolucionando a las empresas tanto por la manera en que influye sobre las herramientas de trabajo como en la perspectiva de los negocios, tener en cuenta que no reemplaza los conocimientos y el ingenio de los humanos, la evidencia es que es un apoyo en operaciones profesionales del día a día, también en el

procesamiento y observación de datos de gran volumen y aceleran las actividades del negocio en general.

Con el uso de la inteligencia artificial y con la base de información disponible sobre sus aplicaciones, se ofrece a los colaboradores de la organización alternativas de las acciones que se pueden emprender. En tal sentido, la Inteligencia Artificial ayuda a los humanos a pronosticar las posibles consecuencias de cada acción y agiliza la toma de decisiones.

Para la investigación se usó una metodología de inteligencia artificial creando redes neuronales artificiales (RNA) los cuales fueron 6 configuraciones con diferentes parámetros, con la intención de llegar a la red que pronostica con más exactitud, se realizó los pasos de normalización, entrenamiento, validación, comprobación de la red y el pronóstico para la red más exacta.

En base a los fundamentos teóricos estudiados se puede aplicar a una empresa de manufactura de fundición para pronosticar los costos de parada de línea, ayudar en la toma de decisiones en el planificación y control de la producción creando planes de mejoras en mantenimiento ya que se tiene los pronósticos por la RNA, provocando un menor tiempo de parada de línea, aumentar la productividad, satisfacer a los clientes y generar más ingresos económicos a la empresa en estudio.

### **1.5.2. Justificación Practica**

Desde el punto de vista práctica, el uso de una metodología con inteligencia artificial es importante porque le ofrece a las empresas de metalmecánica y fundición un conjunto de herramientas que le permitan pronosticar por ejemplo el tiempo de parada de las líneas de producción, luego crear un plan de mantenimiento basado en el resultado de la simulación con inteligencia artificial, de tal manera sea más efectiva y precisa, con el cual se beneficia a la planificación y control de la producción, incrementando la productividad reduciendo

los tiempos de parada de una línea productiva o también se puede evitar la pérdida de oportunidades de negocio y una mayor capacidad de respuesta en la planificación productiva, lo que favorece a la empresa y a los clientes.

### **1.5.3. Justificación Cuantitativa**

Desde el punto de vista cuantitativo, la metodología con inteligencia artificial se justifica porque realizará una simulación para pronosticar los tiempos de parada de la línea A120 en los meses analizados, dicho valor será comparado con una simulación convencional, luego se aplicará una propuesta de mantenimiento para reducir los tiempos de parada aumentando la producción, reduciendo los costos de parada de S/.143,561.95 a S/.43,068.58, también aumenta la producción de (91%) a (96%) y reducir los tiempos de parada de 69 horas a 35 horas en los 4 meses consecutivos simulados.

### **1.5.4. Justificación Social**

Aprovechando la capacidad de automatización de la IA, se pueden delegar a estos sistemas las tareas cotidianas que requieren mucho tiempo con acciones repetitivas, de esta forma los empleados pueden utilizar su tiempo en tareas de análisis, diseño, creatividad, planificación y otras actividades que el empleado prefiere, lo cual mejora tanto la motivación y el clima laboral en las empresas.

Los avances tecnológicos en la IA han contribuido a mejorar la calidad de vida de las personas con discapacidad física, también creación de nuevas prótesis y equipos de diagnósticos. En la industria de la Medicina y la Investigación son las que crearán grandes avances médicos que mejoran la salud de las personas.

## CAPÍTULO II. MARCO TEÓRICO

### 2.1. Antecedentes de la investigación

#### 2.1.1. Antecedentes internacionales

Araujo (2020), presentó en la Universidad Técnica del Norte- Ecuador, para obtener el grado de Ingeniero Industrial; la tesis titulada “*Modelo para la optimización del plan agregado de producción de empresas textiles aplicando técnicas de Inteligencia Artificial - 2020*”; el objetivo general de la investigación fue de diseñar un modelo para optimizar el Plan Agregado de Producción que conduzca al mejoramiento de la productividad y competitividad de empresas textiles mediante la aplicación de técnicas de Inteligencia Artificial, la investigación realizada es tipo aplicada, para el recojo de datos su utilizo la información histórica de empresas textil de la provincia de Imbabura para realizar la investigación se seleccionó una muestra dentro de repositorios de investigaciones realizadas dentro del marco del proyecto CUICYT-UTN: y en sus conclusiones manifestó:

- a) Mediante el análisis y comparación de resultados, bajo un mismo escenario, se obtuvo que la técnica de optimización de enjambre de partículas generó un ahorro significativo de USD 3644,45 con respecto al sistema de transporte utilizado actualmente.
- b) el algoritmo incrementa en 9,84%, 2,77% y 16.72% el nivel de servicio global para las Familias de productos en estudio.

González (2015), presentó en la Universidad de Holguín- Cuba, para obtener el grado de Ingeniero Industrial; la tesis titulada “*Pronóstico de la demanda a través de una Red Neuronal Artificial Perceptrón Multicapa-2015*”; el objetivo general de la investigación es prepara una metodología para el pronóstico de la demanda mediante una Red Neuronal Artificial Perceptrón Multicapa, el trabajo de investigación realizado es de

tipo aplicativo, para el recojo de datos se utilizó la información histórica de la empresa y en sus conclusiones manifestó:

- a) Con la aplicación del procedimiento propuesto se logró determinar con eficacia la demanda para el segundo semestre del 2015 a los productos almohadillas anatómicas superfina b x 10, captopril 10 tabs 25 mg, dipirona 300 mg 10 tabs y Heber-prot-B.
- b) La comparación realizada entre las diferentes redes neuronales existentes posibilitó demostrar la superioridad de la red neuronal perceptrón multicapa y elegirla para su uso en la presente investigación debido a su capacidad de aprendizaje adaptativo.

López (2015), presentó en la Universidad Miguel Hernández de Elche - España, para obtener el grado de doctor; la tesis titulada *“Predicción de la demanda eléctrica utilizando técnicas de inteligencia artificial. Aplicación al mercado eléctrico español. - 2015”*; el objetivo general de la investigación es mejorar la precisión de los modelos actualmente disponibles en su aplicación al sistema eléctrico español, la investigación realizada es tipo aplicativo, para el recojo de datos se utilizó la información histórica de la empresa y en sus conclusiones manifestó:

- a) Los resultados han demostrado que puede establecerse una correlación elevada ( $R^2 > 0.85$ ) entre los valores de estos indicadores y el error de predicción que un modelo de predicción que incluye la temperatura comete al aplicarse a un conjunto de bases de datos del noreste americano.
- b) los resultados más relevantes se han obtenido para el desarrollo de una herramienta que funcione en tiempo real y sea capaz de producir predicciones dentro de un entorno comercial como es el operador del sistema eléctrico español.

### **2.1.1. Antecedentes nacionales**

Díaz (2017), presentó en la Universidad Nacional de Cajamarca- Perú, para obtener el grado de Ingeniero Civil; la tesis titulada *“Uso de las Redes Neuronales Artificiales en el*

*modelado del ensayo de resistencia a compresión de concreto de construcción según la norma astm c39/c 39m- ”*; el objetivo general de la investigación fue determinar el pronóstico de la Resistencia a Compresión del concreto mediante un sistema basado en Redes Neuronales Artificiales, la investigación realizada es tipo aplicada, para el recojo de datos se utilizó una base de registro históricos de diferentes tipos de resistencia a la comprensión; para realizar la investigación se utilizó 13 ensayos a comprensión uniaxial de los datos de la facultad de ingeniería de la Universidad Nacional de Cajamarca - Perú y en sus conclusiones manifestó:

- a) Llego a pronosticar dicha Resistencia utilizando el software MATLAB, demostrando la aplicabilidad de este modelo con un alto grado de confianza.
- b) la Red Neuronal Artificial, ha sido capaz de aprender a reconocer los 3216 ensayos de Resistencia a Compresión procedentes de tesis realizadas en la Facultad de Ingeniería.
- c) El Sistema Experto basado en Redes Neuronales Artificiales que se ha implementado permite automatizar los procesos de entrenamiento y los procesos de pronóstico de Resistencias a la Compresión.

Vergara (2020), presentó en la Universidad Nacional Agraria la Molina - Perú, para obtener el grado de Magister Scientiae en Recursos Hídricos; la tesis titulada *“Simulación y pronóstico de caudales diarios del río Amazonas usando un enfoque híbrido Wavelet y Redes Neuronales- 2020”*; el objetivo general de la investigación fue desarrollar un modelo con inteligencia artificial con un enfoque híbrido (wavelet y redes neuronales) para simular y pronosticar caudales diarios del río Amazonas, la investigación realizada es tipo aplicada, para el recojo de datos se basó en los datos disponibles; para realizar la investigación se seleccionó una muestra estadísticamente disponible en Perú y en sus conclusiones manifestó:



a) Todos los modelos formulados alcanzaron estadísticos desempeños aceptables, sin embargo, el modelo RNA4 obtuvo el mejor desempeño

b) Por lo tanto, estos hallazgos ayudarán a los hidrólogos y tomadores de decisión en el pronóstico de caudales y la planificación y gestión sostenibles de los recursos hídricos.

Zavaleta y Rodríguez (2010), presentó en la Universidad Nacional Mayor de San Marcos- Perú, para obtener el grado de Ingeniero de Sistemas; la tesis titulada *“Sistema de pronóstico de la demanda de productos farmacéuticos basado en redes neuronales- 2010”*; el objetivo general de la investigación fue elaborar un sistema de pronóstico de la demanda de productos farmacéuticos más adecuado mediante el uso de la técnica de Redes Neuronales Artificiales, la investigación realizada es tipo aplicativa experimental, para el recojo de datos se utilizó los datos históricos del producto; para realizar la investigación se seleccionó una muestra histórica de 5 años de la empresa distribuidora y en sus conclusiones manifestó:

a) haciendo uso de una herramienta brindada por el MATLAB (Neural Network), que ofrece la posibilidad de diseñar una red ajustada al desarrollo de nuestro problema.

b) Los resultados obtenidos son buenos ya que con la poca cantidad de datos históricos se llegó a un margen de error del producto del 3,57 % que comparado con el error del 31,23% de la persona encargada de las compras.

c) Así mismo los márgenes de error del 4,93 % y 6,38 % correspondientes al producto RG y CH respectivamente son menores a los errores del experto.

## **2.2. Bases Teóricas**

### **2.2.1. Primera variable: Metodología de Simulación con Inteligencia Artificial**

#### **2.2.1.1. Inteligencia artificial.**

la IA es la habilidad de los ordenadores para hacer actividades que normalmente requieren inteligencia humana. También, para brindar una definición más detallada, podríamos decir que la IA es la capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones tal y como lo haría un ser humano (Rouhiainen, 2018). Sin embargo, las personas difieren de los dispositivos basados en IA por lo que no necesitan descansar y pueden analizar grandes cantidades de información a la vez. Asimismo, la diferencia de errores es altamente menor en las máquinas que realizan los mismos procesos que las contrapartes humanas.

La percepción de que las computadoras o los programas informáticos puedan aprender y tomar decisiones es particularmente importante, es algo sobre lo que deberíamos ser conscientes, de tal manera que su utilización está creciendo exponencialmente con el tiempo. Debido a estas capacidades, las aplicaciones con inteligencia artificial pueden realizar muchas de las tareas que antes eran exclusivas de los humanos.

Las tecnologías basadas en la IA están siendo utilizados para dar una ayudar a los humanos para beneficiarse de las mejoras y disfrutar de una mayor eficiencia en muchos ámbitos de la vida. Pero el gran aumento del uso de la IA también nos obliga a estar sigilosos para prevenir y analizar las posibles amenazas directas o indirectas que pueda generar la proliferación de la IA por el mal uso del humano (Rouhiainen, 2018).

La IA se puede utilizar en casi todas las ramas. Éstas son algunas de las aplicaciones técnicas de la IA que se está incrementando rápidamente en la actualidad.

### 2.2.1.2. Redes Neuronales Artificiales (RNA)

Las primeras investigaciones sobre las RNA proceden de principios del siglo XIX, pero fue hasta los cuarenta del siglo XX cuando el estudio de las RNA cobró mayor fuerza gracias al movimiento conexionista. Este movimiento sostenía la idea que el secreto para el aprendizaje y el conocimiento se encontraba en axiomas o verdades incuestionables y que el conocimiento esta liberado de la estructura que maneje los símbolos, y la figura del conocimiento se hace desde la capa más básico de la inteligencia (Tawfiq, 1999).

No existe una definición general de red neuronal artificial, existiendo diferentes según el texto o artículo consultado (Serrano, Soria y Martin, 2010). Lo cual nos encontramos con las siguientes definiciones:

- a) Una red neuronal es un patrón computacional, paralelo, con una mezcla de unidades procesadoras adaptativas con una elevada interconexión entre ellas.
- b) Sistemas de procesamiento de la información que hacen uso de algunos de los principios que organizan la estructura del cerebro humano.
- c) Modelos matemáticos desarrollados para emular el cerebro humano.
- d) Sistema de procesamiento de la información que tiene características de funcionamiento comunes con las redes neuronales biológicas.
- e) Sistema caracterizado por una red adaptativa combinada con técnicas de procesamiento paralelo de la información.
- f) Desde la perspectiva del reconocimiento de patrones las redes neuronales son una extensión de métodos clásicos estadísticos.


Las definiciones expuestas de cada autor las define de una manera. Parece ser que en todas ellas aparece el componente de simulación del comportamiento biológico.

### 2.2.1.2.1. Elementos básicos de las RNA

Una RNA es muy similar a lo que en matemática discreta se analiza y estudia como "grafos".

En el caso más simple, cada neurona tiene unas variables respecto a sí misma. En todo modelo artificial de neurona se tienen cuatro elementos básicos (Tawfiq, 1999):

- Un sumador**, que se encarga de sumar todas las entradas multiplicadas por las respectivas sinapsis.
- Un conjunto de conexiones**, pesos o sinapsis que determinan el comportamiento de la neurona. Dichas conexiones pueden ser excitadoras (presentan un valor de signo positivo), o inhibitoras (conexiones de valor de signo negativo).
- Una función de activación**, lineal o no lineal para limitar la amplitud de la salida de la neurona.
- Un umbral exterior**, que determina el umbral por encima del cual la neurona se activa.
- Esquemáticamente, una neurona artificial queda representada en la Figura 6

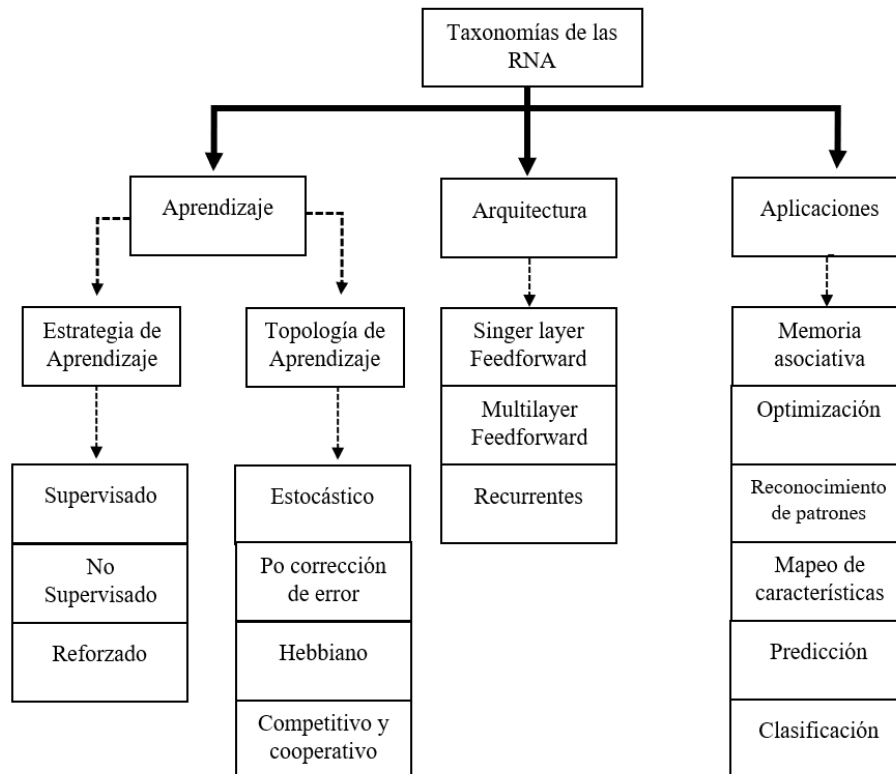


**Figura 6.** Representación de una red neuronal artificial  
*Fuente:* (Sancho, 2018)

### 2.2.1.2.2. Clasificación de las RNA

En la literatura de las redes neuronales Artificiales se encuentran diversas formas de clasificación de acuerdo a sus características.

A continuación, se menciona la taxonomía de RNA que tiene más relación con el problema estudiado (Charytoniuk, 2000).



**Figura 7.** Taxonomía de las RNA según algunos de sus parámetros  
*Fuente:* (Charytoniuk,2000)


Se observa en la **figura 7**; la taxonomía general de las redes neuronales que permite separa la ubicación en la que se mantiene la investigación sobre la predicción con RNAs

Los elementos básicos se pueden conectar entre sí para lograr las estructuras neuronales o modelos conexionistas que se pueden clasificar de diferentes formas según (Charytoniuk, 2000)

### 2.2.1.2.2.1 Según su Arquitectura


Por su arquitectura se puede clasificar en:

- a) **Redes Neuronales Monocapas.** Es la red neuronal más simple ya que se tiene una capa de neuronas que envían información de las entradas a una capa de neuronas de salida donde se realizan los diferentes cálculos (Flórez y Fernández, 2008).



**Figura 8.** Estructura de una red neuronal monocapa  
*Fuente:* (Flórez y Fernández, 2008)


- b) **Redes Neuronales Multicapa.** Es una ampliación de la anterior aumentando una cantidad de capas intermedias entre la entrada y la salida (Flórez y Fernández, 2008).



**Figura 9.** Estructura de una red neuronales multicapa  
*Fuente:* (Flórez y Fernández, 2008)

Se observa en la **figura 9**; la estructura de la red multicapa que consta de capas de entrada, capas ocultas y capa de salida.

- c) **Redes Neuronales Recurrentes.** Esta red se caracteriza por la existencia de uniones de realimentación. Estas conexiones pueden ser entre neuronas de diferentes capas también de neuronas de la misma capa o desde una misma neurona (Flórez y Fernández, 2008).



**Figura 10.** Estructura de una red neuronal recurrente  
*Fuente:* (Flórez y Fernández, 2008)

#### 2.2.1.2.2.2 Según Su Aprendizaje.

Por su aprendizaje se puede clasificar en:

- a) **Aprendizaje Supervisado.** En este aspecto se clasifican las redes neuronales que tienen un controlador en el desarrollo de la red, esto significa que existe un parámetro de semejanza el cual es comparado con las salidas de la red (Flórez y Fernández, 2008).
- b) **Aprendizaje No Supervisado.** Estas redes no tienen referencia de comparación por lo tanto contemplan la autoorganización y autoasociación logrando el proceso de obtención de la salida de la red (Flórez y Fernández, 2008).

### 2.2.1.2.2.3 Según su Aplicación.

Por su aplicación se puede clasificar en:

- a) Redes de Clasificación. Se clasifican por el uso del aprendizaje no supervisado para obtener patrones de clasificación por el ingreso de las entradas del problema (Flórez y Fernández, 2008).
- b) Redes de predicción. Las redes de predicción tienen como objetivo modelar una función no lineal (Flórez y Fernández, 2008).

### 2.2.1.2.3. Parámetros de la red.

Según (Pino, 2002) se examina algunos parámetros para la preparación de la red.

Seguidamente, se muestran las más importantes:

- 1) **Topología de la red.** La red considera la cantidad y definición de las variables de entrada y salida del programa a desarrollar, así como el patrón de red a utilizar, los más utilizados es el perceptrón multicapa, los mapas kohonen y otros, de tal manera se define el número de neuronas y las funciones de activación en cada una de la capa de la red neuronal. Seguidamente, se nombra los parámetros utilizados para la red (Serna, 2017).

**W<sub>ij</sub>:** Peso de la neurona i hacia la neurona j

**W<sub>jk</sub>:** Peso de la neurona j hacia la neurona k

**N:** Neuronas para la capa de entrada

**O:** Neuronas para la capa oculta

**Y:** Neuronas para la capa de salida

- 2) **Algoritmo de aprendizaje.** Los algoritmos más utilizados en el desarrollo de las RNA son el backpropagation y todas sus variantes. El algoritmo presenta 2 fases que se muestra a continuación:

- a) Fase de Aprendizaje o Entrenamiento



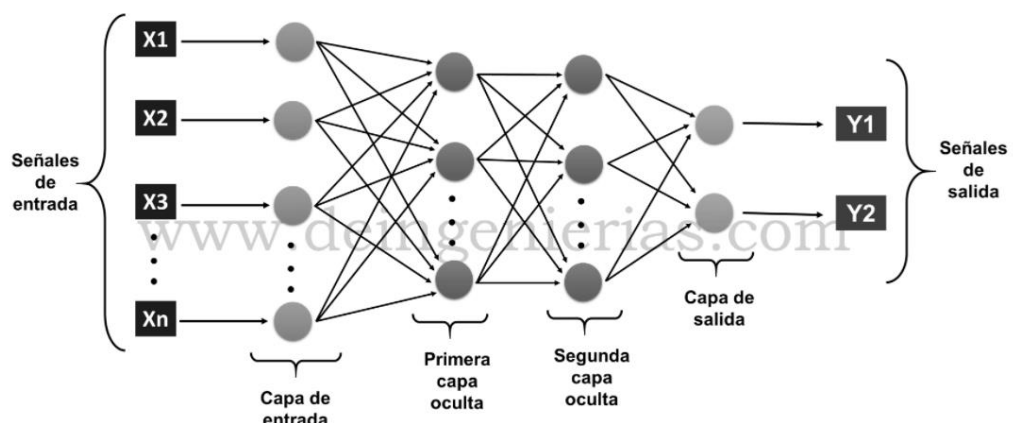
b) Fase de Recuerdo

El propósito es mantener actualizado los pesos de la capa oculta por lo cual se retropropaga el error hacia la capa intermedia (Serna, 2017).

#### 2.2.1.2.4. El Perceptrón Multicapa.

Dentro de las redes supervisadas unidireccionales, la estructura más utilizada es el llamado perceptrón multicapa (MLP, multilayer perceptron). La arquitectura de este tipo de red está formada por varias capas con interconexión completa entre ellos. El caso más sencillo en este tipo de red consiste en sólo dos capas de neuronas, la de entrada y la de salida. De esta manera, se puede obtener un modelo adecuado para problemas lineales del tipo de la regresión lineal múltiple. Si se quiere analizar problemas no-lineales, es necesario incorporar otras capas de neuronas intermedias u ocultas (Trujillano, March y Sorribas, 2004).

(Rodríguez, 2014), Afirma que su arquitectura surge en una combinación de esfuerzos de diversos autores (Werbos, 1974; Parker, 1985; Rumelhart, Hinton, y Williams, 1986; Parker, 1987; Werbos, 1988, 1989); por enmendar las deficiencias que las redes iniciales, Adaline y Perceptrón.



**Figura 11.** Estructura del perceptrón multicapa.

Fuente: (Gil y Rodríguez, 2010).

Tiene además una alta capacidad de generalización y robustez, que genera que la pérdida de una neurona no altere el resultado (Gil y Rodríguez, 2010). De tal manera que, no es la solución perfecta en muchos casos, sobre todo por su alto tiempo de entrenamiento en configuraciones complejas, esta red está ampliamente desarrollada, teniendo aplicaciones en diversos campos como:

- a) El reconocimiento del habla
- b) El reconocimiento óptico de caracteres
- c) El control de procesos
- d) La predicción de series temporales
- e) La conducción de vehículos.

El perceptrón multicapa presenta una estabilidad, según muestra la **Tabla 2**

**Tabla 2**

*Comparativo del perceptrón con las demás RNAs*

Criterio/Modelo	Perceptrón multicapa (Back-Propagation)	Red de Elman (Back-Propagation)	Red de Base radiales (Back-Propagation)	Red de Jordan (Back-Propagation)
Convergencia	<b>5</b>	<b>5</b>	<b>5</b>	<b>5</b>
Minimización del error	<b>4</b>	<b>4</b>	<b>4</b>	<b>4</b>
Complejidad de la red	<b>3</b>	<b>1</b>	<b>1</b>	<b>1</b>
Robustez	<b>3</b>	<b>3</b>	<b>3</b>	<b>0</b>
Tiempo de entrenamiento	<b>1</b>	<b>1</b>	<b>2</b>	<b>1</b>
Total	<b>16</b>	<b>14</b>	<b>15</b>	<b>11</b>

*Nota:* El perceptrón obtiene un puntaje de 16 a comparación de las otras RNAs

#### 2.2.1.2.5. Ventajas de las RNAs.

Las redes neuronales artificiales (RNAs) tienen muchas ventajas debido a que están basadas en la estructura del sistema nervioso, principalmente el cerebro (Jaramillo ,2005). Seguidamente se nombran las más importantes:

- a) **Aprendizaje.** Las RNAs tienen la característica de aprender mediante una fase que se llama etapa de aprendizaje. Consiste en suministrar a la RNA datos de entrada y se le indica cuál es el tipo de dato de salida esperada.
- b) **Auto organización.** Una RNA crea su propia representación de la información en su interior, descargando al usuario las características de dicha información.
- c) **Tolerancia a fallos.** Debido a que una RNA contiene la información de forma redundante, ésta sigue funcionando de manera correcta aun si se daña parcialmente.
- d) **Tiempo real.** La distribución de una RNA es paralela, de tal modo, si esto es aplicado en computadoras o en dispositivos electrónicos, se puede conseguir respuestas en tiempo real.

#### 2.2.1.2.6. Aplicaciones de las RNAs.

Las RNAs son en la práctica muy útiles en problemas en los que se asume una alta tolerancia a la imprecisión y en los que tenemos un número elevado de datos de entrenamiento, pero donde la aplicación de reglas rápidas y robustas no es posible.

Las RNAs con una simple capa oculta son consistentes estimadores estadísticos para la regresión de funciones, y, por supuesto, excelentes clasificadores binarios. Actualmente son usadas en procesos de control, ayuda a la decisión clínica, ayuda a discapacidades físicas, modelización de mercados financieros, reconocimiento de patrones, etc. (Serna, 2017)

Las RNAs son de gran demanda en los campos de investigación en actualidad, según

muestra la **Tabla 3**

**Tabla 3**

*Usos prácticos de las RNAs*

<b>Campos de Investigación</b>	<b>Aplicaciones</b>
Ciencias de la Computación.	Aprendizaje de sistemas, procesado de la información no simbólica....
Estadística	Modelos clasificadores, regresiones no lineales,
Ingenierías	Control automático, procesado de señales, ...
Ciencias del Conocimiento	Modelos de pensamiento y conciencia. (Función Cerebral de Alto Nivel)
Neurofisiología	Modelos de memoria, sistemas sensores y motores. (Función Cerebral de Nivel Medio)
Física	Modelos de fenómenos en mecánica estadística,
Biología	Interpretación de secuencias de nucleótidos
Filosofía	Aprendizaje Inducido/Reforzado/Tutelado/...
<i>Nota:</i> Uso de las RNAs en los diversos campos de investigación	

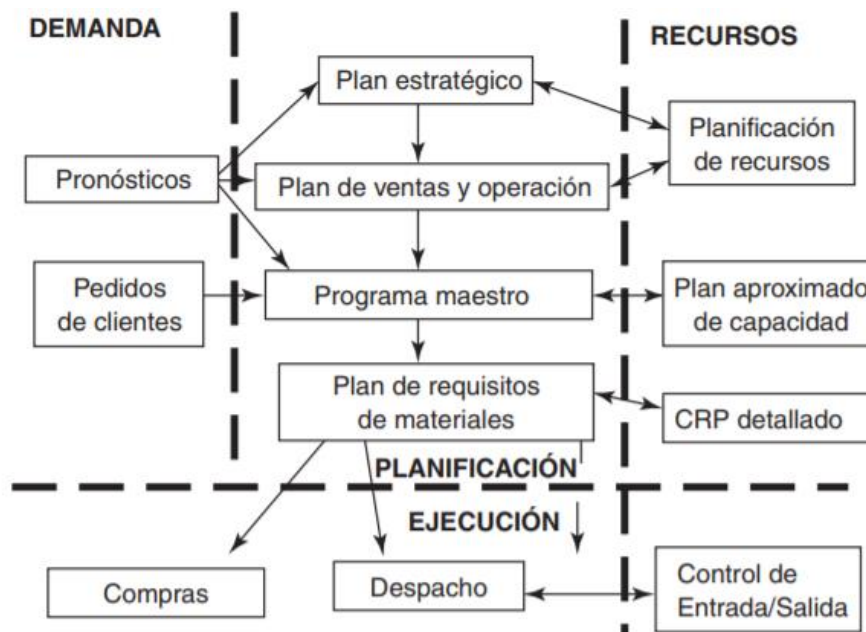
## 2.2.2. Segunda variable: Planificación y Control de Producción, en Sistemas de Manufactura de Fundición.

### 2.2.2.1. Planificación y Control de Producción (PCP).

#### 2.2.2.1.1 Definición

Son procedimientos administrativos de prioridad y capacidad usadas para planificar y controlar las operaciones productivas. El control de la prioridad asegura que las actividades de producción sigan un plan (Ejemplo, el plan de requerimientos de materiales) controlando las órdenes a los proveedores y la producción interna.

El control de las capacidades del área ayuda monitorear los centros de trabajo para consolidar de que se está suministrando la cantidad de mano de obra y horas de equipo que es necesario para realizar el trabajo programado (Caba, Chamorro y Fontalvo, 2011).



**Figura 12.** Actividades de planificación y control de una empresa

Fuente: (Chapman, 2006)

### 2.2.2.1.2 Elementos del PCP

Se muestran algunos elementos básicos (Caba, Chamorro y Fontalvo, 2011):

- a) **Control** (relacionado con el tipo de sistema)
- b) **Control**. (referidos a los trabajos y el tiempo de producción)
- c) **Razón crítica**. Técnica de programación dinámica.
- d) **Despacho**. Selección y programación de trabajos.
- e) **Expedición**. Encontrar la discrepancia entre el trabajo planeado y el realizado.
- f) **Control de entradas**. Control sobre el trabajo.
- g) **Tiempo de entrega**. Ciclo entre la decisión de planificar una orden y la culminación de las primeras unidades de pedido.
- h) **Línea de balance**. Técnica gráfica que usa tiempos de entrega y secuencia de ensamble.
- i) **Cargas**. Asignación de las horas de trabajo.
- j) **Control de salidas**. Despacho de cualquier obra técnica de control necesaria, para lograr el trabajo programado
- k) **Programación**. Fijar las fechas de inicio de actividades de los trabajos
- l) **Tiempo de arranque**. Tiempo requerido para ajustar una máquina

### 2.2.2.1.3 Objetivos del PCP y Datos Requeridos

El PCP debe proporcionar información segura sobre (Caba, Chamorro y Fontalvo, 2011):

- a) El estado actual de los trabajos (ejemplo, qué órdenes están en proceso y dónde).
- b) Trabajos pendientes.
- c) La adecuación de materiales y capacidad.
- d) Utilización de equipo y mano de obra.
- e) Progreso, eficiencia y los trabajos.


### 2.2.2.2. Fundición

La fundición es una forma de metalurgia extractiva. El proceso de fundición es calentar a altas temperaturas y reducir los residuos del mineral para obtener un metal puro, y apartarlo de la ganga y otros posibles elementos (Scott, 2011)

También se conoce a fundición al procedimiento de fabricar objetos con metales fundidos mediante moldes. En otros procesos de fundición se utilizan electrodos de carbono, pero en las plantas de diseño más actuales se usan electrodos que no se consuman. El producto final es aluminio fundido, cobre fundido, o hierro fundido (Scott, 2011)

### 2.2.2.3. Línea de Producción.

Una línea de producción la forman una serie de estaciones de trabajo ordenadas para que los productos pasan de una estación a la siguiente y en cada posición se realice una parte del trabajo total. La rapidez de producción de la línea se define por medio de su estación más lenta. Las estaciones de trabajo más rápidas, llegarán a verse afectado y limitados por la estación más lenta, que representa un cuello de botella de la línea (Groover, 1997).



**Figura 13.** Estructura las etapas de una línea de producción

*Fuente:* (Groover, 1997).

#### 2.2.2.4. Productividad

Es la capacidad para producir con la velocidad más alta posible, es la celeridad para transformar la energía en cosas y recursos, es la acción para desarrollar el conocimiento y la creatividad, es mostrar rápido las mejores leyes sociales, es la rapidez de utilizar materiales para crear arte, es la velocidad para lograr trabajo intelectual o físico (López, 2012).

$$\text{PRODUCTIVIDAD} = \frac{\text{PRODUCCIÓN}}{\text{TIEMPO}}$$

*Ecuación 1.* Productividad (P)

#### 2.2.2.5. Tiempo de parada

Son los procesos que utilizan las fábricas para detener de manera temporal su producción, que tienen como objetivo ejecutar labores de mantenimiento o reparación de equipos, agregar reformas para elevar la capacidad de producción o incorporar nuevas tecnologías que logren mejorar el sistema productivo de la empresa.

#### 2.2.2.6. Costo de parada de línea

El coste de parada de producción por avería, es el dinero que dejas de ganar por producirse una avería y perder tiempo de producción. Se verifica que una maquina parada supone importantes pérdidas para la empresa (Yepes, 2015)

#### 2.2.2.7. Rentabilidad

Para realizar cualquier proyecto de inversión, se debe primero evaluar, de manera que disminuya el nivel de incertidumbre y riesgo (Van y Wachowicz, 2001). Las formas más usadas para medir las empresas, son los indicadores de rentabilidad (Anthony y Govindarajan, 2003).



La rentabilidad se puede medir en dos formas, con métodos simples y métodos complejos.

El primero recurre al uso de los estados financieros de la empresa, pero sin considerar el valor del dinero en el tiempo, el segundo sí considera el valor del dinero en el tiempo, y tienen mayor utilización en el sector privado. Estos métodos complejos de rentabilidad son: Valor Actual (VA), Valor Actual Neto (VAN), Tasa Interna de Retorno (TIR) y el Periodo de Recuperación de la Inversión (PRIN) (Bazzani y Cruz, 2008).

### **2.2.3 Teorías relacionadas a las variables de estudio**

#### **2.2.3.1. Herramienta Informática MATLAB.**

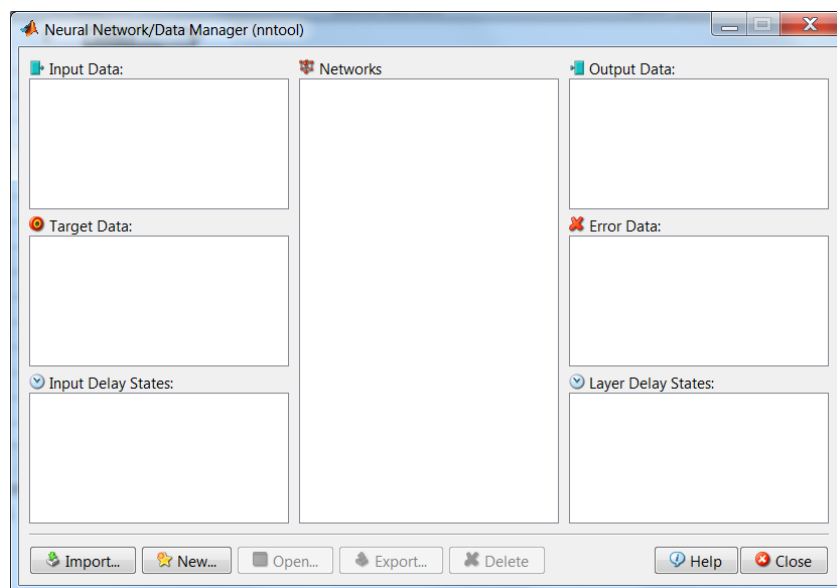
La herramienta informática MATLAB, constituye en la actualidad una herramienta matemática muy completa que permite un cálculo avanzado de cualquier procesamiento matemático que deseamos realizar a partir de un modelado anterior. Esta herramienta informática es hoy en día de uso frecuente en cualquier titulación científica o técnica, está más relacionada con los estudios enfocados a la ingeniería. En este sentido, constituye un software utilizado en multitud de universidades y centros de investigación de todo el mundo y de temática muy diversa (Reinoso, Jiménez, Payá, Gil y Vidal, 2018)

La herramienta de MATLAB está preparada para resolver problemas científicos y de ingeniería. La herramienta de MATLAB, basado en matrices que es la forma más natural para expresar el mundo en las matemáticas utilizando las computadoras. El ambiente de invita a ensayar, explorar y descubrir. Todas estas herramientas y funciones de MATLAB están demostradas rigurosamente y diseñadas para trabajar juntas. (Moore, 2012).

Sus características principales:

- a) Lenguaje de alto nivel para cálculos científicos y de ingeniería
- b) Entorno de escritorio optimizado para la exploración iterativa, el diseño y la solución de problemas
- c) Gráficas para visualizar datos y herramientas para crear diagramas personalizados

- d) Aplicaciones para ajustar curvas, clasificar datos, analizar señales, ajustar sistemas de control y muchas otras tareas
- e) Toolboxes complementarias para una amplia variedad de aplicaciones científicas y de ingeniería
- f) Herramientas para crear aplicaciones con interfaces de usuario personalizadas
- g) Interfaces para C/C++, Java®, .NET, Python, SQL, Hadoop y Microsoft® Excel®
- h) Opciones de implementación libres de derechos para compartir programas de MATLAB con los usuarios finales.
- i) **Neural Network Toolbox (NNTool) de Matlab:** Es herramienta de redes neuronales de Matlab consagrada que se utiliza para crear, entrenar y simular las RNAs (Ciaburro, 2017).



**Figura 14.** Herramienta NNtool para el diseño de las RNA  
*Fuente:* (Ciaburro, 2017).

### 2.2.3.2. La Demanda

#### 2.2.3.2.1. Definición.

La demanda se refiere a las cantidades de un producto que los consumidores están dispuestos a comprar a los posibles precios del mercado (González ,2014).

#### 2.2.3.2.2 Elementos básicos de la demanda.

A continuación, se describen un conjunto de partes que conforman la demanda (Mankiw, 2012):

- a) **Cantidad de bienes o servicios.** Son los números de unidades que los clientes estarían preparado para comprar o que ya se han adquirido.
- b) **Compradores o consumidores.** Se refiere a las personas, empresas u organizaciones que obtiene algunos productos para satisfacer sus necesidades.
- c) **Necesidades y deseos.** La necesidad es el estado que se siente por la privación de algunos factores básicos del ser humano (alimentación, vestimenta, cobijo, seguridad). Del otro lado, los deseos es anhelar los algo específico.
- d) **Disposición a adquirir el producto o servicio.** Se refiere al individuo, empresa u organización para satisfacer alguna necesidad o deseo.
- e) **Capacidad de pago.** Se refiere al individuo, empresa u organización tiene los recursos necesarios para lograr la adquisición.
- f) **Precio dado.** Es el valor expresado comúnmente en términos monetarios que son determinados a un bien o servicios.
- g) **Lugar establecido.** Es el lugar, físico o virtual, en el que los compradores están listos para realizar la adquisición.

La demanda es una función matemática que es expresada mediante la ecuación:

$$Q = F (P, I, G, N, Ps, Pc)$$

*Ecuación 2.* Cantidad demandada (Q)

Donde

$Q$  = Cantidad demandada.

$P$  = precio del bien o servicio.

$I$  = ingreso del consumidor.

$G$  = gustos y preferencias.

$N$  = número de consumidores.

$P_s$  = precio de bienes sustitutos.

$P_c$  = precio de bienes complementarios.

### **2.2.3.3. El Pronóstico**

#### **2.2.3.3.1. Definición**

Un pronóstico, en el plano empresarial, es la predicción de lo que sucederá con elemento determinado dentro del marco de un conjunto dado de condiciones. Se diferencia del presupuesto porque este último es el resultado de decisiones encaminadas a generar las condiciones que propiciarán un nivel deseado de dicho elemento (Hanke y Wichern, 2006)

Los pronósticos se utilizan en el proceso de creación de objetivos en el largo y corto plazo, integrando así en pilares para el desarrollo de planes, de forma general y en las áreas de la empresa (Keat y Young, 2004)

#### **2.2.3.3.2. Clasificación de pronósticos**

Según la intensidad del uso de datos se clasifican en (Keat y Young, 2004):

- a) **Pronósticos cualitativos.** La base es el juicio de individuos o grupos de individuos, se pueden exponer de forma numérica pero regularmente no se basan en datos históricos.

- b) **Pronósticos cuantitativos.** Se utilizan cantidades altas de datos previos como base para la predicción. Los cuales son:
1. **Simples:** proyectan datos pasados hacia el futuro sin explicar las tendencias futuras.
  2. **Causales:** Explica las relaciones funcionales entre la variable a ser pronosticada y la variable o variables que detallan los cambios

#### 2.2.3.3.3. El proceso del pronóstico.

Un pronóstico se elabora siguiendo los pasos siguientes:

- a) **Formulación del problema y recolección de datos.** Los dos elementos mencionados, se toman como un único paso porque el problema define los datos adecuados. Si no se dispone de los datos adecuados el problema tendría que redefinirse o se tendría que acudir a un método puramente cualitativo (Robbins, 2005).
- b) **Manipulación y limpieza de datos.** Al tener muchos o pocos datos, se presentan algunos problemas. Los datos irrelevantes, datos desactualizados y otros, exigirán cierto procesamiento para obtener los datos precisos y adecuados.
- c) **Construcción y evaluación del modelo.** Es utilizar los datos en el modelo de pronóstico que este más adecuado para la minimización del error de pronóstico.
- d) **Aplicación del modelo.** Es el pronóstico real del modelo que se origina de una vez que se han recogido y reducido los datos convenientes.
- e) **Evaluación del pronóstico.** Es la comparación de los datos obtenidos por el pronóstico con los datos históricos reales. (Robbins, 2005).

#### 2.2.3.4. Trefiladora

La trefiladora es una máquina de producción utilizada para fabricar alambres. En el proceso trefilado se hace pasar el alambre a través de las hileras, para reducir su sección.

La trefiladora es principalmente de una matriz puesta en un troquel, la cual variará la sección del cobre a su paso por ella, por su forma, con una sección de entrada menor que la de salida. (Wright, 2011).



**Figura 15.** Línea trefiladora de hilos de cobre  
*Fuente:* (Wright, 2011).

#### 2.2.3.5. Diagrama de Pareto


##### a) Definición

El diagrama de Pareto es un gráfico en el cual la información es analizada mostrando luego mediante un diagrama de barras de forma descendente y en relación a su prioridad. También se le denomina curva cerrada. Esto nos permite conocer el orden de prioridad de las variables que se analiza.

##### b) Uso del diagrama de Pareto

Se basa en la ley de Pareto. Fue un ingeniero que planteo una regla que se cumple. Encontró que el 80% de los procesos que se realizan son triviales y solo se entina en un 20% del tanteo y a la inversa. De tal manera, la segunda es a las que hay que dar

un mayor esfuerzo. La interpretación del diagrama de Pareto es crucial en muchas áreas de la empresa. Por ejemplo, en marketing parece cumplirse que aproximadamente el 20% de clientes genera el 80% del ingreso. Por tal motivo, es en ellos en los que deberemos concentrar el 80% de nuestro tiempo y a la inversa. El diagrama de Pareto nos ayuda a conocer qué actividades son esenciales según este principio (Rus, 2020).

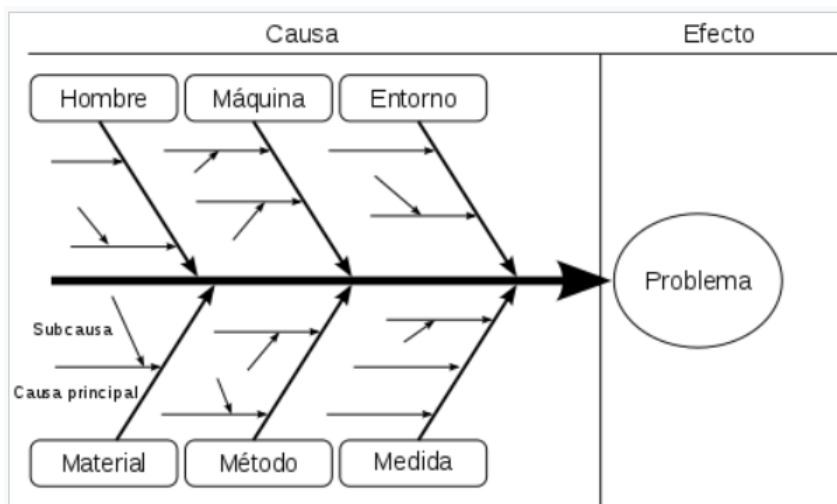


**Figura 16.** Estructura del diagrama de Pareto

*Fuente:* (Rus, 2020).

#### 2.2.3.6. Diagrama de Ishikawa

Lo llaman también diagrama de cola de pescado o diagrama de causa efecto, es un diagrama que por su estructura ha sido llamado también diagrama de espina de pez. Consiste en una gráfica sencilla que representa lo que puede observarse de manera relacional con una forma de espina central, que es una línea en el plano horizontal, mostrando el problema para examinar, que se escribe a su lado derecho. Es una de las diferentes herramientas surgidas a lo largo del siglo XX en campo de la industria y después en los servicios, para mejorar el análisis de problemas y generar soluciones, como en la calidad de los procesos, los productos y servicios (Johannes, 2021).



**Figura 17.** Esquema de causa efecto.  
*Fuente:* (Johannes, 2021).

### 2.2.3.7. Normalización de datos

El proceso de normalización es necesario para nuestro trabajo puesto que se desea uniformizar los datos ya que las unidades de cada variable son disímiles y se diferencian de manera notable. Con este proceso de normalización se procura obtener valores uniformes de entrada en un rango de 0-1 para que no se produzca dependencias de ninguna variable para el logro del resultado ya que cada una de ellas influyen en el pronóstico de manera análoga. Este procedimiento se lleva a cabo mediante de la división de todos los datos de una variable común que es el mayor de los mismos, se muestra la ecuación de normalización:

$$D_n = D_i / MD$$

**Ecuación 3.** Normalización de datos ( $D_n$ )

**$D_n$**  = Valor Normalizado

**$D_i$**  = Variable de entrada

**$MD$**  = Valor máximo de la variable de entrada



### 2.2.3.8. Error cuadrático medio (ECM)

El ECM mide el promedio de los errores al cuadrado, en concreto encuentra la diferencia entre el estimador y lo que se estima. El ECM es una función de riesgo, propio al valor previsto de la disminución del error al cuadrado.

La variación se produce por la aleatoriedad o porque no se tiene en cuenta la información que llevaría a producir una pronóstico más preciso.

$$\text{ECM} = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2.$$

**Ecuación 4.** Error cuadrático medio (ECM)

Donde:

ECM = Error cuadrático medio.

n = Cantidad de muestras para la validación.

$\hat{Y}_i$  = Salida objetivo de la red para la muestra i.

$Y_i$  (w) = salida estimada de la red para la muestra i.

### 2.2.3.9. Cantidad prevista por el experto

Es la cantidad que el experto en la empresa calcula se venderá en el mes dado de acuerdo a la siguiente fórmula estadística:

$$\text{CP } i = (\text{CDi-1} + \text{CDi-2} + \text{CDi-3}) / 3$$

**Ecuación 5.** Cantidad prevista por el experto (CPi)

Donde:

CPi → Cantidad Pronosticada del mes i

CDi-1 → Cantidad Demanda Real del mes i-1

CDi-2 → Cantidad Demanda Real del mes  $i-2$

CDi-3 → Cantidad Demanda Real del mes  $i-3$

#### **2.2.3.10. Mantenimiento 5S**

Es una metodología japonesa utilizada comúnmente para la implementación de sistemas de calidad total. El objetivo de la metodología es propiciar un ambiente de trabajo agradable y eficiente, el cual permita el correcto desempeño de las operaciones diarias, logrando así los estándares de calidad, de precio y características de entrega solicitados por el cliente.

#### **2.2.3.9. Mantenimiento Autónomo**

Es una de las etapas de la preparación de las condiciones para la implantación del TPM, el cual es la más difícil y toma mayor tiempo en realizar, esto implica que es difícil de dejar la forma habitual de trabajo, los operadores y operarios de mantenimiento se les dificulta dejar su forma habitual de trabajo, los operadores trabajan a tiempo completo en la producción y el personal de mantenimiento asume por completo las responsabilidades de las reparaciones (Nakajima, 1991).

### 2.3. Definición de términos básicos

**Inteligencia artificial:** (Rouhiainen, 2018). La IA es la facultad de las máquinas para utilizar algoritmos, memorizar los datos y utilizar lo aprendido en la toma de decisiones tal con el ser humano lo hace.

**Redes Neuronales Artificiales:** Según (Callejas, Piñeros, Rocha, Hernández y Delgado, 2013), forman parte de la Inteligencia Artificial, además (Oliveira, Ferrari, Da Silva, y Tech, 2015) indican que son redes entrenadas mediante las entradas obtenidas desde los escenarios externos o internos en el sistema y estas entradas encontradas se multiplican por pesos determinados al azar.

**Perceptrón Multicapa:** Dentro de las redes supervisadas unidireccionales, la estructura más utilizada es el llamado perceptrón multicapa (MLP, multilayer perceptron). La estructura típica de esta red está formada por varias capas de nodos con interconexión completa entre ellos.

Además, posee una elevada capacidad de generalización y robustez, que provoca que la pérdida de una neurona no afecte al resultado (Zavaleta y Collas, 2010)

**Entrenamiento:** Las RNA son sistemas dinámicos auto-adaptativos. Se adaptan debido a su capacidad de autoajuste de los elementos procesales que son las neuronas, que conforman el sistema. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones (Matich, 2001).

**Validación:** Es validar los resultados de una aplicación a través de la determinación de las desviaciones (error), con respecto a la demanda conocida de un período anterior (Acosta, Villarreal, y Cabrera, 2013).

**Tasa de error:** cantidad que representa la diferencia entre la cantidad pronosticada por la red neuronal y la demanda real

**Matlab:** Que corresponde a la abreviatura de Matrix Laboratory, constituye hoy en día una herramienta matemática muy potente que posibilita un cálculo avanzado de cualquier procesamiento matemático que se tenga realizar a partir de un modelado previo (Reinoso, Jiménez, Payá, Gil y Vidal, 2018)

**Neural Network Toolbox:** MATLAB cuenta con la herramienta Neural Network Toolbox que proporciona algoritmos, funciones y aplicaciones para crear, entrenar, visualizar y simular redes neuronales además se puede realizar clasificación, regresión, agrupación, reducción de dimensionalidad, predicción de series de tiempo y modelado y control de sistemas dinámicos (Smith, 2017).

**Productividad:** La productividad es el uso que se le da a los recursos disponibles para obtener una cierta cantidad de producto, es decir la productividad es un indicador que refleja la eficiencia con que se gestionan las personas, el capital, los conocimientos, la energía, para producir bienes y servicios (Viteri, 2015).

**Tiempo de parada:** Son los procesos que realizan las fábricas para detener de manera parcial su producción. Tienen como prioridad realizar trabajos de reparación de equipos, agregar reformas para elevar las capacidades de la producción o introducir nuevas tecnologías que logren mejorar el sistema productivo.

**Costo de parada:** El coste de parada de producción por avería, es el dinero que dejas de ganar por producirse una avería y perder tiempo de producción. Se verifica que una maquina parada supone importantes pérdidas para la empresa (Yepes, 2015)

**Rentabilidad:** Son métodos de cálculo, el objetivo fundamental de toda empresa desde el punto de vista económico - financiero es conseguir que a medio y largo plazo sea rentable (Jaime, 2016)

**Mantenimiento 5S:** Es una metodología japonesa utilizada comúnmente para la implementación de sistemas de calidad total.

**Mantenimiento Autónomo:** Es una de las etapas de la preparación de las condiciones para la implantación del TPM.

## CAPÍTULO III. METODOLOGIA

### 3.1. Tipo de Investigación

La investigación es de tipo explicativo, debido a que se utiliza la herramienta “Metodología de simulación con inteligencia artificial” para mejorar la “Planificación y control de producción” en las actividades de los sistemas de manufactura de fundición.

#### a) Población y muestra.

##### 1) La población.

La población de estudio de la investigación está conformada por 18 registros de tiempo de parada, que suman 260.28 horas y que representa a 18 meses de producción, desde enero del 2018 hasta marzo del 2019, en la línea trefiladora A120, para la fabricación de alambres de cobre en la empresa del rubro fundición.

##### 2) La muestra.

López y Fachelli (2015) afirman que, la muestra puede ser el censo, es decir, la relación exhaustiva de todas las unidades poblacionales: de habitantes, electoral, de viviendas, de empresas, de escuelas, de hospitales, un archivo de instituciones, asociaciones, empresas, usuarios, clientes, un mapa, el listado de teléfonos, un catálogo, todos los artículos de un diario en un período dado, los internautas de un portal, etc.

La muestra de la investigación corresponde a toda la población que son los tiempos de parada de la línea trefiladora A120 que corresponden a 260.28 horas de parada de línea, desde enero del 2018 hasta marzo del 2019.

### **3.2. Técnicas e instrumentos de recolección y análisis de datos**

Para la recopilación de datos se emplean tres procedimientos metodológicos; cuantitativo, cualitativo y la observación directa.

#### **3.2.1. Técnica de recolección de datos:**

Los procedimientos utilizados en esta investigación fueron:

##### **a) Observación.**

Heinemann (2003) afirma que, se tienen un contacto directo con los elementos o caracteres en los cuales se presenta el fenómeno que se pretende investigar, y los resultados que se obtienen se consideran datos estadísticos originales.

Permitió verificar el estado actual en la que se encontró el servicio de mantenimiento de la línea trefiladora, también se conoció el método de recolección de los tiempos de parada de los equipos de la línea trefiladora.

Esta observación se realizó de forma presente con la aprobación y autorización del gerente general y la participación del jefe de mantenimiento (Anexo 1: Hoja Informativa).

Por consideraciones de seguridad de la empresa, las evidencias fotográficas no fueron autorizadas, esto debido a soltar información interna que perjudique su posición en el mercado, otorgando ventaja a las empresas competidoras del rubro.

##### **b) Análisis documental.**

Mediante el análisis documental se lograron conocer los siguientes puntos (Anexo 2: Análisis documental):

- 1) El registro de datos históricos de los tiempos de parada CP de la línea.
- 2) La de demanda productiva de la línea trefiladora.
- 3) El precio por tonelada de producto generado por la línea trefiladora
- 4) La producción x hora de la línea trefiladora.
- 5) Las fallas más recurrentes de los equipos de la trefiladora.
- 6) Los equipos que conforman la línea trefiladora.
- 7) El plan de producción para la línea trefiladora

### **3.2.2. Instrumentos de recolección de datos:**

Los instrumentos de recolección de datos para la investigación referente a la Metodología de simulación con inteligencia artificial para mejorar la planificación y control de producción, en las actividades de los sistemas de manufactura de fundición, se detallan a continuación:

- a) Ficha de observación: Se registran las actividades de la línea trefiladora como los mantenimientos correctivos, preventivos también la información relaciona a los tiempos de parada. (Anexo 2: Ficha de observación).
- b) Ficha de registro digital (archivo de Excel)
- c) Cámara interna del celular.

### **3.2.3. Instrumentos de análisis de datos.**

Peersman (2014) afirma que, la planificación de la recolección de datos debe comenzar por revisar en qué medida pueden utilizarse los datos existentes. Para los términos de



indicadores, la valorización debe intentar basarse en diferentes tipos de indicadores (insumos, productos, resultados, impactos) para reflejar los principales hallazgos en la teoría del cambio del programa.

Los instrumentos de análisis de datos para la investigación referente a la Metodología de simulación con inteligencia artificial para la mejora en la Planificación y control de producción en los sistemas de manufactura de fundición, se detallan a continuación:

- a) Microsoft Excel: Se utilizó para registrar las horas de parada, cálculo del costo de parada de la línea trefiladora, la realización de la normalización de datos para la RNA, el análisis económico del proyecto de investigación y la identificación de las variables de entrada a la RNA (Anexo 2: Ficha de observación).
- b) Neural Network Toolbox (nntool): se utilizó para crear la RNA necesaria para el pronóstico de los costos de parada de línea y la validación de los datos generados por la RNA (Anexo 2: Ficha de observación).

### **3.3. Procedimientos para el desarrollo de la investigación**

#### **1. Presentación**

Se presenta una metodología de ayuda alternativa para la mejora del proceso de planeación de la producción con redes neuronales artificiales (RNA). La información al respecto pone en evidencia un tiempo elevado por las paradas de línea, afectando a los indicadores de producción. Se espera una mejora de la planeación y control de la producción en la línea trefiladora de la empresa en estudio del rubro fundición, que nos permita aumentar el nivel de rendimiento, disponibilidad y confiabilidad operacional de las máquinas.

#### **2. Marco Normativo (Marco legal)**

Comisión Europea: Nueva normativa en materia de IA - 21 de abril de 2021

#### **3. Justificación del programa**

- a) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite pronosticar por ejemplo los costos de parada de la línea, por medio de un conjunto de herramientas y esto beneficia directamente a incrementar las utilidades de la empresa.
- b) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite aportar una ayuda en la toma de decisiones en el plan de producción, generando más producción en la línea y esto beneficia a los planificadores de la producción de la línea.
- c) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite pronosticar el tiempo de parada de la línea provocados por las fallas de los equipos que conforman y esto beneficia a los técnicos del área de mantenimiento que ya están prevenidos de las posibles fallas, el cual les permite

realizar un plan más eficaz para mantener la línea de producción activa el mayor tiempo posible.

#### **4. Alcance del programa**

El presente programa de Metodología de Simulación con Inteligencia Artificial, en una empresa de fundición y metalmecánica, tiene como alcance la jurisdicción de Los Olivos-Lima, dicha investigación se realizó en el periodo desde enero 2018 hasta junio 2019

#### **5. Objetivos del programa**

- a) Describir los lineamientos de la metodología con RNA, planificación, ejecución, verificación, en sistemas de manufactura de fundición
- b) Describir los procedimientos de ejecución de la “Metodología de Simulación con Inteligencia Artificial”
- c) Elaborar una matriz de ejecución
- d) Describir los resultados a obtener

#### **6. Lineamiento de la planificación, ejecución, verificación y acción de la “Metodología de Simulación con Inteligencia Artificial”**

##### **6.1 Planificación**

Realizar un diagrama de Ishikawa de la línea y hallar los costos de parada de la línea

##### **6.2. Ejecución**

Desarrollo de la Metodología de Simulación con Inteligencia Artificial

Paso 1: Construcción de la RNA base

Paso 2: Recopilación de datos Históricos

Paso 3: Diseño de la Topología de la RNA

Paso 4: Normalización de los datos para la RNA

Paso 5: Entrenamiento de la RNA del Costo de parada de línea CP

Paso 6: Validación de la RNA

Paso 7: Selección de la RNA más exacta para el Pronóstico de CP

Paso 8: Datos obtenidos por el pronóstico de la RNA seleccionada

### 6.3. Verificación y acción

- a) Demostración mediante la herramienta Neural Networks de Matlab
- b) Demostración mediante el Procedimiento Analíticos

## 7. Matriz de Ejecución

- a) **Realizar normalización de datos históricos:** En gabinete, se usó el Ms Excel y calculadora y duro una semana.
- b) **Creación de la red base, realizar los entrenamientos, validación, selección de la RNA y realizar el pronóstico:** En gabinete, se usó el Matlab y duro tres semanas.
- c) **Realización de la verificación de los datos generados por el pronóstico de la RNA:** En gabinete, se usó el Matlab y duro una semana.

## 8. Evaluación y acción

los indicadores de evaluación y acciones son:

- a) **Planeación y control de la producción:** costo de parada línea, tiempo de parada línea y producción de línea.
- b) **Rentabilidad:** utilidad e ingresos

## 9. Presupuesto

Para realizar la investigación se utilizó los recursos de la empresa, como el uso de un equipo de cómputo que proporciono el área de mantenimiento y también se utilizó el equipo de cómputo de uso propio.

Ver el Programa completo en el Anexo 2.

## CAPÍTULO IV. RESULTADOS

### 4.1. Desarrollo el objetivo específico 1

**Objetivo específico 1:** Determinar cómo una metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

Para el cumplimiento de objetivo específico 1, se realizó 2 procedimientos:

- a) Mediante la aplicación de la herramienta Neural Networks de Matlab
- b) Mediante métodos analíticos de verificación

#### 4.1.1 Demostración mediante la herramienta Neural Networks de Matlab

Se muestra un resumen de la simulación con inteligencia artificial para el pronóstico de costo de parada de línea en la Tabla 4.

**Tabla 4**

*Pasos para el pronóstico del costo de parada de línea mediante RNA*

<b>Pasos</b>	<b>Procedimiento</b>
<b>Paso 1: Construcción de la RNA base</b>	La construcción de la red neuronal base se determinó a partir de los parámetros de entrada y salida de la red que corresponden a las variables influyentes en el mantenimiento de los equipos de la línea trefiladora.
<b>Paso 2: Recopilación de datos Históricos</b>	Se deben de elegir cuidadosamente las variables a emplear en la RNA, se trata es incluir en el modelo las variables predictoras.
<b>Paso 3: Diseño de la Topología de la RNA</b>	El tipo de red neuronal artificial que se va a utilizar es un perceptrón multicapa (MPL).
<b>Paso 4: Normalización de los datos para la RNA</b>	El proceso de normalización fue necesario para nuestro trabajo de investigación puesto que se desea uniformizar los datos.
<b>Paso 5: Entrenamiento de la RNA del Costo de parada de línea CP</b>	La fase de entrenamiento de una red neuronal sirve para asociar un patrón de entradas a un patrón de salidas, en el estudio se realizaron 6 configuraciones de RNA.
<b>Paso 6: Validación de la RNA</b>	El proceso de validación de las redes neuronales seleccionadas que fueron Simulacion_CP_05, Simulacion_CP_04 y Simulacion_CP_01.
<b>Paso 7: Selección de la RNA más exacta para el Pronóstico de CP</b>	Se analizó las RNAs, de los cuales se tomó como modelo la red Simulacion_CP_05 por presentar el menor ECM.
<b>Paso 8: Datos obtenidos por el pronóstico de la RNA seleccionada</b>	Se pronostica con la red seleccionada en el Matlab obteniendo datos que luego serán comparados con los datos reales de los costos de parada de la línea para verificar la exactitud.

*Nota:* Elaboración propia

En la tabla 4, se muestra un resumen de los pasos para el pronóstico del costo de parada de línea mediante una RNA. Ver procedimiento de pronóstico completo en Anexo 6

Después de realizar el entrenamiento y validación se procedió a realizar el pronóstico con la RNA, tales resultados serán evaluados y comparados en los siguientes pasos:

### **Paso 1: Resumen del entrenamiento de la RNAs del costo de parada línea CP**

Después de que se normalizo los datos, luego se seleccionó los datos entrada con los datos de validación posteriormente se realizó las configuraciones para el entrenamiento y validación de la RNAs

De los datos obtenidos se deduce que las 3 configuraciones más adecuadas son: Simulacion\_CP\_01, Simulacion\_CP\_04 y el Simulacion\_CP\_05 puesto que estas redes poseen los menores valores de ECM

**Tabla 5**  
*Entrenamiento de la RNAs*

<b>Resultados Obtenidos</b>				
Red Neuronal	Capas ocultas		Épocas	ECM
	Capa 1	Capa 2		
Simulacion_CP_01	5	5	100	0.000635
Simulacion_CP_02	6	6	60	0.00218
Simulacion_CP_03	7	7	100	0.000949
Simulacion_CP_04	7	7	150	0.0000117
Simulacion_CP_05	9	9	50	0.0000109
Simulacion_CP_06	9	9	200	0.00144

*Nota:* Elaboración propia

Se muestra el compendio de los resultados obtenidos en las 6 configuraciones de redes, también se muestran los datos más importantes empleados en el entrenamiento de cada red neuronal que referencian al nombre de la red, al número de neuronas por cada capa oculta, luego se muestra el número de épocas realizadas por cada red en su respectivo

entrenamiento y el rendimiento o performance equivalente a la función del error cuadrático medio (ECM).

### **Paso 2: Configuración escogida para el Pronóstico con RNA del CP**

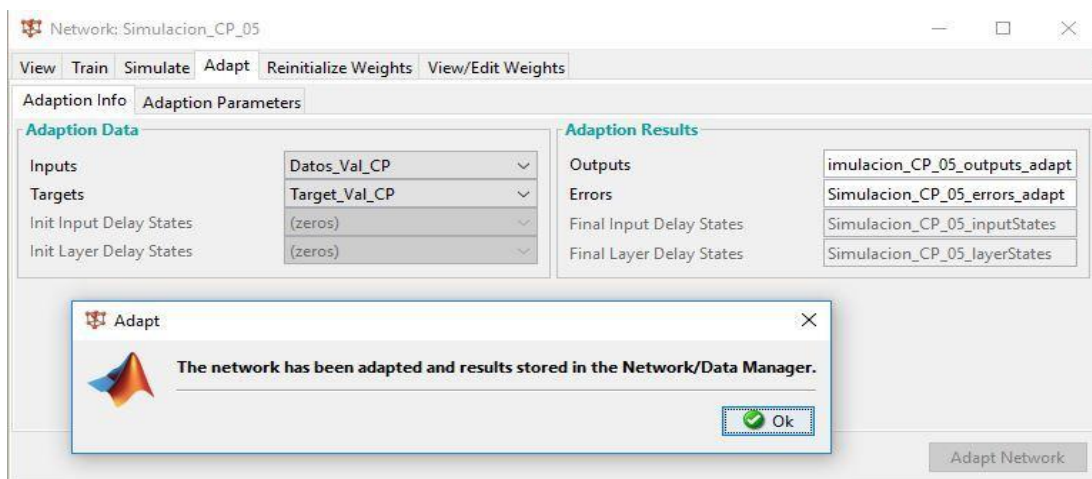
La primera red seleccionada es la red “Simulacion\_CP\_05”, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.0000109, la segunda es la red “Simulacion\_CP\_04” cuyo valor de ECM es 0.0000117 y la tercera es la red “Simulacion\_CP\_01” que presenta un error de 0.000635. Estas 3 redes serán empleadas para la fase de validación donde a partir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico del costo de parada en la línea trefiladora CP.

### **Paso 3: Validación de las RNAs del costo de parada de línea CP**

El proceso de validación de las redes neuronales seleccionadas que fueron Simulacion\_CP\_05, Simulacion\_CP\_04 y Simulacion\_CP\_01 se realizó utilizando la interfaz Neural Networks (nntool) de la caja de herramientas de MATLAB, cuyo procedimiento, resultado y pruebas se mostrará a continuación.


En la interfaz Neural Networks del MATLAB se cargan las entradas para la validación y las salidas para la misma, se muestra el vector de error de validación, con los errores resultantes.





**Figura 18.** Simulación con los datos de validación para la red Simulacion\_CP\_05

*Fuente:* elaboración propia



**Figura 19.** Errores de la validación Simulacion\_CP\_05

*Fuente:* elaboración propia

#### **Paso 4: Hallando la tasa de error de las RNAs seleccionadas**

La tasa de error será medida utilizando la fórmula del error cuadrático medio para comprobar que el tipo de red seleccionado es el más confiable en la predicción.

$$\mathbf{Ec} = \frac{1}{N} \sum_{i=1}^N ||y^i - s^i(w)||^2$$

**Ecuación 6.** Tasa de error medio de la RNA (EC)

Donde:

$E_c$  = Error cuadrático.

$N$  = Número de muestras en la validación.

$Y_i$  = Dato de salida objetivo de la RNA para la muestra  $i$ .

$S_i(w)$  = Dato de salida estimada de la RNA para la muestra  $i$

A continuación, en la figura se observan los resultados obtenidos

<b>Simulacion_CP_05</b>				
	<b>Valor Real</b>	<b>Valor Prediccion</b>	<b>Diferencia</b>	<b>ECM</b>
Mar-19	<b>0.9027</b>	0.98900	-0.08627	<b>0.09525</b>
Abr-19	<b>0.2957</b>	0.40566	-0.10996	
May-19	<b>0.5066</b>	0.48531	0.02133	
Jun-19	<b>0.7855</b>	0.91324	-0.12769	
<b>Simulacion_CP_04</b>				
	<b>Valor Real</b>	<b>Valor Prediccion</b>	<b>Diferencia</b>	<b>ECM</b>
Mar-19	<b>0.9027</b>	0.97494	-0.07221	<b>0.13219</b>
Abr-19	<b>0.2957</b>	0.30698	-0.01128	
May-19	<b>0.5066</b>	0.31215	0.19449	
Jun-19	<b>0.7855</b>	0.62206	0.16349	
<b>Simulacion_CP_01</b>				
	<b>Valor Real</b>	<b>Valor Prediccion</b>	<b>Diferencia</b>	<b>ECM</b>
Mar-19	<b>0.9027</b>	0.90459	-0.00186	<b>0.12571</b>
Abr-19	<b>0.2957</b>	0.29559	0.00011	
May-19	<b>0.5066</b>	0.25552	0.25112	
Jun-19	<b>0.7855</b>	0.79748	-0.01193	

**Figura 20.** Resultados de los ECM de las RNAs.

*Fuente:* elaboración propia

A continuación, se muestran las RNAs validadas, siendo la red Simulacion\_CP\_05 que genera el menor ECM.

**Tabla 6**

*Comparativo de los ECM de las configuraciones de las RNAs*

<b>Resultados Obtenidos para costo de parada CP</b>			
Red Neuronal	Capas Ocultas		ECM
	Capa 1	Capa 2	
Simulacion_CP_05	9	9	0.09525
Simulacion_CP_04	7	7	0.13219
Simulacion_CP_01	5	5	0.12571

*Nota:* Elaboración propia

### **Paso 5: Elección de RNA para el Pronóstico de CP**

Se analizó las RNAs, de los cuales se tomó como modelo la red Simulacion\_CP\_05 por presentar el menor ECM, con el cual se realizar el pronóstico de los meses marzo, abril, mayo y junio del 2019 para el costo de parada de línea trefiladora A120.

Variables - Simulacion_CP_05_outputs_adapt{1, 1}					
Simulacion_CP_05_outputs_adapt{1, 1}					
1	2	3	4	5	6
0.9890	0.4057	0.4853	0.9132		

**Figura 21.** RNA seleccionada para el pronóstico del costo de parada de línea A120

*Fuente:* elaboración propia

### **Paso 6: Datos pronosticados por la RNA seleccionada**

Como los datos pronosticados se muestran normalizados, se tiene que convertirlos a sus valores normales para después realizar la comparación con los datos reales.

Proceso de conversión de los datos normalizados, se multiplica el máximo valor de costos de parada real por el dato normalizado, resultando el valor original, de la misma manera con los datos resultante del pronóstico de la RNA.

**Para la conversión del mes de marzo 2019 el costo de parada de línea real es:**

Costo de las horas de parada de línea(convertido)= S/57,640.934 \* **0.9027** = S/ **52,034.453**

**Para la conversión del mes de marzo 2019 el costo de parada pronosticada RNA es:**

Costo de las horas de parada pronosticado (convertido)=S/57,640.934 \* **0.98900**= S/

**57,006.884**

**Tabla 7**

*Valores de costo de parada de línea pronosticado en Yi*

Máximo valor	Yi			
	Costo de las horas paradas (normalizado)	Costo de las horas de parada de línea(convertido)	Costo de las horas de parada de línea pronosticado (normalizado)	Costo de las horas de parada pronosticado (convertido)
Mar-2019	<b>0.9027</b>	S/ 52,034.453	0.98900	S/ 57,006.884
Abr-2019	<b>0.2957</b>	S/ 17,044.604	0.40566	S/ 23,382.621
May-2019	<b>0.5066</b>	S/ 29,203.239	0.48531	S/ 27,973.722
Jun-2019	<b>0.7855</b>	S/ 45,279.656	0.91324	S/ 52,640.007

*Nota:* Elaboración propia

#### **4.1.2. Demostración mediante el Procedimiento Analíticos**

##### **Paso 1: Rendimiento de la RNA frente al experto**

EL objetivo más trascendental fue poder pronosticar el costo de las horas de parada de línea CP con un margen de error mínimo o menor a la del experto. Para poder demostrar esta presunción presentamos las evidencias, que demuestran que nuestra red neuronal predice los montos generados por la parada de la línea trefiladora A120 con menor margen de error que el experto usando fórmula de pronósticos por tiempos que es promedio simple.

$$CP\ i = (CDi-1 + CDi-2 + CDi-3) / 3$$

**Ecuación 7.** Rendimiento de la RNA (C*Pi*)

Donde:

**C*Pi*:** Cantidad Pronosticada del mes i

**CDi-1:** Cantidad Real del mes i-1

**CDi-2:** Cantidad Real del mes i-2

**CDi-3:** Cantidad Real del mes i-3

Se presenta las variables de producción de la línea trefiladora para calcular los costos de parada de línea trefiladora A120

**Tabla 8**

*Valores de las variables de producción en la línea*

<b>Variables</b>	<b>Valor</b>	<b>Unidad</b>
Producción x hora (ph)	0.833	tn/hr
Precio x tonelada (p)	795.00	\$
Tipo de cambio (tc)	3.400	S/.

*Nota:* Elaboración propia

Ecuación para el cálculo del costo de parada d línea:

Costo de las horas paradas de la línea trefiladora =	(horas de parada de línea) *(producción x hora) *(precio x tonelada) *(tipo de cambio)
--	--

**Ecuación 8.** Costo de las horas de parada de línea (CP)

Con las variables de producción de la línea se procede a realizar los cálculos para los meses en estudio, como ejemplo para el mes de marzo, abril, mayo y junio del 2019:

**Tabla 9**

*Valores obtenidos para el costo de parada de línea según la ecuación*

Mes	Costo de parada de línea
CP (marzo 2019)	$23.11 * 0.833 * 795 * 3.4 = S/ 52,034.45$
CP (abril 2019)	$7.57 * 0.833 * 795 * 3.4 = S/ 17,044.60$
CP (mayo 2019)	$12.97 * 0.833 * 795 * 3.4 = S/ 29,203.24$
CP (junio 2019)	$20.11 * 0.833 * 795 * 3.4 = S/ 45,279.66$

*Nota:* Elaboración propia

Aplicando la formula se obtiene los costos de parada de línea de todos los meses que se utilizan en esta investigación.

**Tabla 10** *Costos de parada de línea para los meses en estudio*

Mes	Horas de parada(hrs)	Costo de las horas paradas de la línea trefiladora
Ene-2018	16.32	S/36,738.59
Feb-2018	5.42	S/12,196.16
Mar-2018	15.68	S/35,312.58
Abr-2018	1.67	S/3,752.67
May-2018	25.60	S/57,640.93
Jun-2018	14.48	S/32,610.66
Jul-2018	15.11	S/34,021.66
Ago-2018	10.32	S/23,236.50
Set-2018	20.60	S/46,382.94
Oct-2018	8.42	S/18,958.46
Nov-2018	11.10	S/24,992.75
Dic-2018	19.70	S/44,356.50
Ene-2019	14.86	S/33,458.76
Feb-2019	12.44	S/28,009.89
Mar-2019	23.11	S/52,034.45
Abr-2019	7.57	S/17,044.60
May-2019	12.97	S/29,203.24
Jun-2019	20.11	S/45,279.66

*Nota:* Elaboración propia

**Paso 2: Hallar los pronósticos del experto usando el método de promedio simple**

- a) **Pronosticó el costo de parada de la línea trefiladora A120 por el método de Promedio simple para el mes de marzo 2019**

Mes = marzo 2019 donde  $i = 3$

$$CP = (CD \text{ (febrero)} + CD \text{ (enero)} + CD \text{ (diciembre)}) / 3$$

$$CP = (28,009.89 + 33,458.76 + 44,356.50) / 3$$

$$CP = 35,275.051 \text{ soles de Costo de Parada}$$

- b) **Pronosticó el costo de parada de la línea trefiladora A120 por el método de Promedio simple para el mes de abril 2019**

Mes = abril 2019 donde  $i = 4$

$$CP = (CD \text{ (marzo)} + CD \text{ (febrero)} + CD \text{ (enero)}) / 3$$

$$CP = (S/52,034.45 + S/28,009.89 + S/33,458.76) / 3$$

$$CP = S/37,834.37 \text{ soles de Costo de Parada}$$

- c) **Pronosticó el costo de parada de la línea trefiladora A120 por el método de Promedio simple para el mes de mayo 2019**

Mes = mayo 2019 donde  $i = 5$

$$CP = (CD \text{ (abril)} + CD \text{ (marzo)} + CD \text{ (febrero)}) / 3$$

$$CP = (S/17,044.60 + S/52,034.45 + S/28,009.89) / 3$$

$$CP = S/32,362.98 \text{ soles de Costo de Parada}$$

**d) Pronosticó el costo de parada de la línea trefiladora A120 por el método de Promedio simple para el mes de junio 2019**

Mes = junio 2019 donde  $i = 6$

$$CP = (CD \text{ (mayo)} + CD \text{ (abril)} + CD \text{ (marzo)}) / 3$$

$$CP = (S/29,203.24 + S/17,044.60 + S/52,034.45) / 3$$

$$CP = S/32,760.77 \text{ soles de Costo de Parada}$$

### 4.1.3 Comparación del Pronostico de la RNA y el Método del Experto

A continuación, se muestra el cuadro comparativo entre las cantidades pronosticadas por el experto encargado de realizar las previsiones en la empresa y las cantidades pronosticadas por la red neuronal Simulacion\_CP\_05 entrenada y validada para el CP, así mismo se muestran los errores por cada mes de la red neuronal y del experto tomando como referencia los meses de marzo, abril, mayo y junio del año 2019 que corresponden a los datos de validación.

**Tabla 11**

*Comparación de método del experto y de la RNA para los costos de parada de línea.*

**Resultados Obtenidos del Pronóstico de Costo de Parada CP en línea trefiladora A120**

i	Mes	Monto previsto por el experto(S/)	Monto pronostic ado por la RN(S/)	Monto de CP Real(S/)	Error del experto( S/)	Error de la RN(S)
1	Marzo- 2019	35,275.051	57,006.884	52,034.45	<b>16,759.40</b>	<b>4,972.43</b>
2	Abril - 2019	37,834.368	23,382.621	17,044.60	<b>20,789.77</b>	<b>6,338.02</b>
3	Mayo - 2019	32,362.982	27,973.722	29,203.24	<b>3,159.74</b>	<b>1,229.52</b>
4	Junio - 2019	32,760.765	52,640.007	45,279.66	<b>12,518.90</b>	<b>7,360.35</b>
	<b>TOTAL</b>	138,233.17	161,003.23	143,561.95	<b>53,227.80</b>	<b>19,900.32</b>
<b>Error Promedio = (100 * [SUM(Error) / SUM (Monto Real i)]) %</b>					<b>37.08 %</b>	<b>13.86 %</b>

*Nota:* Elaboración propia



De los resultados de la Tabla 11, se deduce que la red neuronal propuesta obtiene mejores predicciones que el experto encargado de las previsiones en la empresa, puesto que el error promedio real obtenido por la RN es de 13,86% valor que es mucho menor comparado con el 37,08 % del experto.

$$\begin{aligned} \text{Error (RN)} &< \text{Error(experto)} \\ 13,86\% &< 37,08\% \end{aligned}$$

### **Cumplimiento del objetivo Específico 1:**

Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial en el pronóstico de los costos de parada de línea, cuyo error (RNA) es 13.86% y el error del experto es 37.08 %; observando que el error cometido por la RNA es menor con respecto al monto real del costo de parada.

## 4.2. Desarrollo el objetivo específico 2

**Objetivo específico 2:** Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición

Para el cumplimiento del objetivo específico 2, se procedió a realizar lo siguiente pasos.

### Paso 1: Obtener las Horas de parada a partir del Pronóstico de la RNA

Mediante los resultados del pronóstico del costo de parada de línea A120 se pudo reconvertir a horas de parada de la línea mediante las variables mostradas.

La tonelada de alambre producida por la línea trefiladora cuesta \$795 y produce 0.833 t/hr.

**Tabla 12**

*Variables de la producción de la línea A120*

Variables	Valor	Unidad
Producción x hora (ph)	0.833	tn/hr
Precio x tonelada (p)	795.00	\$
Tipo de cambio (tc)	3.400	S/.

*Nota:* Elaboración propia

Se muestran las horas de parada de línea obtenidas después de la conversión a partir de los datos del pronóstico de RNA, mostrando las horas para los meses de marzo, abril, mayo, junio del 2019.

**Horas de parada de línea (HPL) = (Costo de las horas paradas de la línea trefiladora) /**

**((producción x hora) \*(precio x tonelada) \*(tipo de cambio))**

**Ecuación 9.** Horas de parada de línea (HPL)

Cálculo de las horas de parada de línea para el mes de mar-2019.

**Horas de parada (mar-2019) =** 57,006.88/ (0.833\*795\*3.4) = 25.32 hrs

**Tabla 13**

*Horas calculadas con los datos del pronosticadas mediante la RNA*

<b>Pronóstico De Costo de Prada CP en Línea Trefiladora</b>		
<b>Mes</b>	<b>Costo de parada de línea pronosticado por la RN</b>	<b>Horas de parada Obtenidas partir del Pronóstico de la RNA del CP</b>
Mar-2019	57,006.88	25.32
Abr-2019	23,382.62	10.38
May-2019	27,973.72	12.42
Jun-2019	52,640.01	23.38

*Nota:* Elaboración propia

## **Paso 2: Mejorando el plan de mantenimiento de la línea trefiladora A120**

### **1. Propuesta del Plan de Mantenimiento Autónomo de la metodología TPM**

Antes de comenzar con las medidas, es necesario explicar a los operadores de la línea trefiladora los objetivos del auto mantenimiento para que puedan entenderlas y adoptarlas, luego ellos puedan proponer mejoras. Por lo tanto, es necesario respetar ciertas reglas que las compañías japonesas llaman 5 S:

- Clasificación eliminación del espacio de trabajo lo que sea inútil (seiri);
- Orden y método(seiton);
- Limpieza y control (seiso);
- Estandarización (seiketsu);
- Disciplina y respeto (shitsuke).

### **Etapas para el mantenimiento autónomo en la línea**

- Limpieza inicial

Los operarios y operadores de la línea trefiladora deberán ordenar su espacio de trabajo, herramientas, máquinas limpias y ordenadas.

- Propuesta y análisis de medidas correctivas

Debes lograr incentivar a los operarios de la línea trefiladora para que ellos mismos quieran mantener su área limpia, logrando que el tiempo de limpieza sea menor.

c) Limpieza y lubricación

Una vez que los operarios de la línea trefiladora conocen y están dispuestos a mantener la limpieza y el orden en su zona de trabajo, también con las herramientas y máquinas, se tiene que realizar protocolos estandarizados para realizar la limpieza, por lo tanto, las 5S es una herramienta ideal para este paso.

d) Inspección general

Cuando se cumplan los primeros 3 pasos, el siguiente es capacitar a los mismos operarios de la línea trefiladora, quienes deben ser formados para seguir avanzando, para realizar inspecciones generales eficaces.

e) Inspección autónoma

Implica el análisis del progreso de los operarios de la línea trefiladora en su desarrollo de adquisición de habilidades, para realizar inspecciones y detectar anomalías, llegando a desarrollar un procedimiento estándar para ejecutar la inspección autónoma

f) Orden y organización

Deben actuar el equipo directivo y los mandos intermedios, del área de producción de la empresa, creando procedimientos y estándares para optimizar el orden y la limpieza aplicando la metodología 5 S.

g) Implementación del mantenimiento autónomo

Los empleados de la línea trefiladora están debidamente formados para realizar un mantenimiento autónomo exitoso, aunque tome tiempo para perfeccionarlo.

## 2. Propuestas Plan de capacitación del personal de la línea trefiladora

**Tabla 14**

*Plan de capacitación de los operadores de la línea*

Tema	Realizado por	Tiempo	Modalidad
Ítem 1: Capacitaciones Mantenimiento Correctivo Repuestos Originales	Empresa Externa	8 horas (febrero), 8 horas (marzo)	1. Teórico 2. Tipo taller 3. Virtual
Ítem 2: Capacitación para la Implementación Efectiva del Mantenimiento Preventivo	Empresa Externa	8 horas (febrero), 8 horas (marzo)	4. Teórico 5. Tipo taller 6. Virtual

*Nota:* Elaboración propia

### Paso 3: Comparativo del plan de mantenimiento anterior y el propuesto

#### 1. Plan de Mantenimiento de la línea anterior

El plan de mantenimiento de la línea trefiladora actual presenta muchas deficiencias lo cual provoca altas paradas de línea.

**Tabla 15**

*Plan del mantenimiento anterior*

<b>Plan de Mantenimiento de línea trefiladora (Anterior)</b>	
<b>Procedimiento</b>	<b>Estado (1-5)</b>
1) Mantenimiento preventivo	2
2) Stock de rodamientos	2
3) Capacitación a los técnicos en ajustes de rodamientos.	1
4) Registro de antigüedad de maquina	2
5) Medición de alineación de alambre	3
6) Incentivos para el personal	1
7) Procedimiento de regulación de alambre	3

*Nota:* Elaboración propia

## Calculando el Eficiencia General de los Equipos (OEE)

Calcularemos la eficiencia general de la línea para el mes enero 2018 y los demás meses

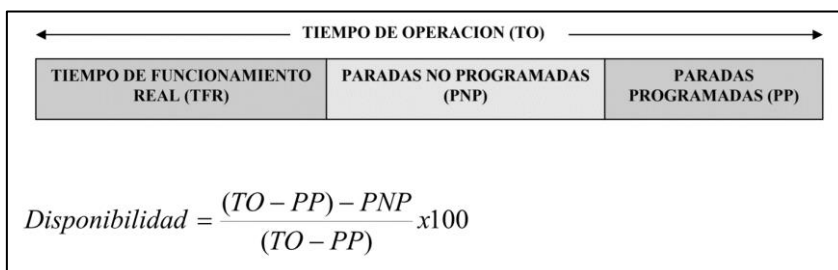
**Tabla 16**

*Variables de producción de la línea*

<b>Variables</b>	<b>Valor</b>	<b>Unidad</b>
Producción x hora (ph)	0.833	tn/hr
Precio x tonelada (p)	795.00	\$
Tipo de cambio (tc)	3.400	S/.
Horas disponibles	630	hrs/mes
Horas de parada Programada	90	hrs/mes

*Nota:* Elaboración propia

Disponibilidad:



### **Ecuación 10.** Disponibilidad

Disponibilidad = (((630-90)-17.32) / (630-90)) \* 100 = 96.79% para el mes de enero 2018

Rendimiento:

$$\text{Índice de Rendimiento} = \frac{\text{Tiempo ideal de ciclo} \times \text{Cantidad procesada}}{\text{Tiempo de funcionamiento real TFR}}$$

### **Ecuación 11.** Rendimiento

Rendimiento = (0.833\*574.68) / (630-90-17.32) = 91.59% para el mes de enero 2018

Calidad

$$\text{Tasa de Calidad} = \frac{\text{Piezas producidas} - \text{Rechazos}}{\text{Piezas producidas}}$$

**Ecuación 12.** Tasa de calidad

Calidad =  $((0.833 * 574.68) - 0) / (0.833 * 574.68) = 100\%$  para el mes de enero 2018

**OEE = Disponibilidad \* Rendimiento \* Calidad**

**Ecuación 13.** Eficiencia general de equipo (OEE)

OEE =  $96.79\% * 91.59\% * 100\% = 88.65\%$  para el mes de enero 2018

**Tabla 17**

*Eficiencia General de los Equipos (OEE) de los meses en estudio*

Mes	Tiempo de parada(hrs)	Horas de producción programadas (hrs)	Horas de producción real(hrs)	Disponibilidad	Rendimiento	Calidad	EGE/OEE
Ene-2018	17.32	592.00	574.68	96.79%	91.59%	100%	88.65%
Feb-2018	7.42	569.00	561.58	98.63%	87.84%	100%	86.63%
Mar-2018	18.68	571.00	552.32	96.54%	88.25%	100%	85.20%
Abr-2018	10.47	560.00	549.53	98.06%	86.45%	100%	84.77%
May-2018	30.60	596.00	565.40	94.33%	92.46%	100%	87.22%
Jun-2018	20.48	574.00	553.52	96.21%	88.75%	100%	85.39%
Jul-2018	22.11	580.00	557.89	95.91%	89.73%	100%	86.06%
Ago-2018	18.32	595.00	576.68	96.61%	92.08%	100%	88.96%
Set-2018	29.60	593.00	563.40	94.52%	91.95%	100%	86.91%
Oct-2018	18.42	586.00	567.58	96.59%	90.65%	100%	87.55%
Nov-2018	22.10	567.00	544.90	95.91%	87.64%	100%	84.06%
Dic-2018	31.70	562.00	530.30	94.13%	86.91%	100%	81.80%
Ene-2019	15.86	580.00	564.14	97.06%	89.66%	100%	87.02%
Feb-2019	14.44	595.00	580.56	97.33%	92.02%	100%	89.56%
Promedio							<b>86.41%</b>

Nota: Elaboración propia

## 2. Propuesta del plan basado en el Mantenimiento Autónomo de la TPM

Se propone un plan de mantenimiento basado en el mantenimiento autónomo y capacitaciones de la persona, para poder reducir los tiempos de parada de la línea trefiladora.

**Tabla 18**

*Propuesta de plan de mantenimiento*

<b>Propuesta de Plan de Mantenimiento</b>
1) Plan de Mantenimiento Autónomo
2) Ítem 1: Capacitaciones Mantenimiento Correctivo Repuestos Originales
3) Ítem 2: Capacitación para la Implementación Efectiva del Mantenimiento Preventivo

*Nota:* Elaboración propia

Con las mejoras en el plan de mantenimiento se espera reducir los tiempos de Parada de la línea trefiladora A120 en un 30%

**Tabla 19**

*Disminución del tiempo de parada aplicando el plan de mantenimiento*

Mes	Costo de parada de línea pronosticado por la RNA(S/)	Horas Obtenidas a partir del Pronóstico de la RNA	Plan de mantenimiento reduce el tiempo de parada de línea en 30%(hrs)
Mar-2019	57,006.88	25.32	7.60
Abr-2019	23,382.62	10.38	3.12
May-2019	27,973.72	12.42	3.73
Jun-2019	52,640.01	23.38	7.01

*Nota:* Elaboración propia

**Cumplimiento del objetivo Específico 2:** Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial, porque al pronosticar los tiempos de parada de los meses futuros que son marzo, abril, mayo y junio del 2019, se puede proponer acciones correctivas como una propuesta de plan de mantenimiento autónomo que reduzca en un 30% los tiempos de parada de la línea.



### 4.3. Desarrollo el objetivo específico 3

**Objetivo específico 3:** Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a la producción de la línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición

Para el cumplimiento del objetivo específico 3, se procedió a realizar lo siguiente pasos:

#### **Paso 1: Obtener las horas de parada de línea de la RNA y aplicar el plan de mantenimiento.**

Se utilizó los datos generados por el pronóstico del costo de parada de línea de la RNA para obtener las horas de parada de línea, luego aplicando el plan de mantenimiento se reduce esas horas de parada de línea en un 30%,

**Tabla 20**

*Variables de producción de la línea*

Variables	Valor	Unidad
Producción x hora (ph)	0.833	tn/hr
Precio x tonelada (p)	795.00	\$
Tipo de cambio (tc)	3.400	S/.
Horas disponibles	630	hrs/mes

*Nota:* Elaboración propia

Como ejemplo para el mes de mar-2019 horas pronosticadas con la RNA es de 25.32.

**Tabla 21**

*Horas de parada de línea obtenidas del pronóstico*

Mes	Costo de parada de línea pronosticado por la RNA(S/)	Horas Obtenidas a partir del Pronóstico de la RNA
Mar-2019	57,006.88	25.32
Abr-2019	23,382.62	10.38
May-2019	27,973.72	12.42
Jun-2019	52,640.01	23.38

*Nota:* Elaboración propia

Con la aplicación del mantenimiento se reduce en 30% las horas de parada de línea como se muestra en la Tabla 22, para el mes de mar-2019 horas pronosticadas es de 25.32 con la mejora se reduce a 17.72 horas, luego la diferencia seria 7.60 hrs de producción recuperado.

**Tabla 22**

*Aumento de la producción aplicando el plan de mantenimiento*

Mes	Horas Obtenidas a partir del Pronóstico de la RNA	Plan de mantenimiento reduce el tiempo de parada de línea en 30%(hrs)	Aumento de la producción de hilos de cobre(tonelada)
Mar-2019	25.32	7.60	6.327
Abr-2019	10.38	3.12	2.595
May-2019	12.42	3.73	3.105
Jun-2019	23.38	7.01	5.842

*Nota:* Elaboración propia

### **Paso 2: Determinar el aumento en la producción:**

Para encontrar la producción de hilos de cobre de la línea trefiladora en el mes estudiados del 2019 se realiza lo siguiente:

Producción (mar-2019) =  $7.60 \text{ h} \times 0.833 \text{ tn/hr} = 6.327 \text{ tn}$

Producción (abr-2019) =  $3.12 \text{ h} \times 0.833 \text{ tn/hr} = 2.595 \text{ tn}$

Producción (may-2019) =  $3.73 \text{ h} \times 0.833 \text{ tn/hr} = 3.105 \text{ tn}$

Producción (jun-2019) =  $7.01 \text{ h} \times 0.833 \text{ tn/hr} = 5.842 \text{ tn}$

**Cumplimiento del objetivo Específico 3:** Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial en la producción ya que, al disminuir las horas de parada de línea con la propuesta del mantenimiento autónomo, se aumenta la producción para los meses de marzo en 6.327tn, para abril 2.595tn, para mayo 3.105tn y para junio 5.842tn. del año 2019.

#### 4.4. Desarrollo el objetivo específico 4

**Objetivo específico 4:** Determinar como una metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición

Para el cumplimiento del objetivo específico 4, se procedió a realizar lo siguiente:

##### **Paso 1: Se calcula las horas de parada de línea de la trefiladora**

Los datos del pronóstico de la RNA son usados para calcular las horas de parada a través del costo de parada.

**Tabla 23**

*Costos de parada de línea de la trefiladora por el pronóstico*

Mes	Costo de parada de línea pronosticado por la RNA(S/)	Horas Obtenidas a partir del Pronóstico de la RNA	Horas de producción real pronosticado con la RNA (hrs)
Mar-2019	57,006.88	25.32	567.68
Abr-2019	23,382.62	10.38	575.62
May-2019	27,973.72	12.42	554.58
Jun-2019	52,640.01	23.38	538.62

*Nota:* Elaboración propia

##### **Paso 2: Aplicado el plan de mantenimiento se reduce las horas de parada de línea**

Aplicado el mantenimiento las horas de parada de línea se reduce en un 30% por ejemplo para marzo del 2019 tiene 25.32 hrs, el cual se reduce 7.6 hrs, esta reducción se convierte en producción de la línea generando S/17,112.15.

Calculo para el mes de marzo 2019

$$\text{Monto marz-2019} = 0.833\text{tn/hr} * 7.6\text{tn} * 3.4 * 795\$ = \$ / 17,112.15$$

**Tabla 24**

*Montos recuperados después reducir los tiempos de parada*

Mes	Horas de producción programadas	Costo de parada de línea pronosticado por la RNA(S/)	Horas Obtenidas a partir del Pronóstico de la RNA	Plan de mantenimiento reduce el tiempo de parada de línea en 30%(hrs)	Ingresos recuperados de la línea trefiladora
Mar-2019	593	S/57,006.88	25.32	7.6	S/17,112.15
Abr-2019	586	S/23,382.62	10.38	3.12	S/7,024.99
May-2019	567	S/27,973.72	12.42	3.73	S/8,398.46
Jun-2019	562	S/52,640.01	23.38	7.01	S/15,783.71
Total					<b>S/48,319.31</b>

*Nota:* Elaboración propia

Se calculan los nuevos ingresos ya que la línea trefiladora tiene más horas disponibles para la producción de hilos de cobre generando ingresos adicionales y dejando una rentabilidad.

En los meses pronosticados que son marzo, abril, mayo y junio del 2019, se obtuvo un ingreso total de S/48,319.31 por las horas adicionales generando rentabilidad para la empresa en estudio.

Nota: la empresa en estudio no proporcionó los costos directos e indirectos por motivo de seguridad, explicando que darían una ventaja a sus competidores.

**Cumplimiento del objetivo Específico 4:** Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial en la rentabilidad de la línea ya que, al disminuir las horas de parada de línea, aumenta la producción, generando ingresos adicionales en marzo de S/17,112.15, abril de S/7,024.99, mayo de S/8,398.46 y junio de S/15,783.71 del 2019, los cuales suman un ingreso total de S/48,319.31.

#### 4.5. Desarrollo el objetivo General

**Objetivo General:** Determinar cómo una metodología de Simulación con Inteligencia

Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.

**Tabla 25**

*Valores obtenidos en los objetivos específicos*

Objetivos	Actual	Con el pronóstico de la RNA
Pronóstico de los costos de parada de línea	Por el experto su error es: 37,08 %	Para el pronóstico su error es: 13,86%
Tiempo de parada de línea	Sin la mejora en el mantenimiento: marzo 2019 → 25.32 hrs abril 2019 → 10.38 hrs mayo 2019 → 12.42 hrs junio 2019 → 23.38 hrs	Con la mejora en el mantenimiento: marzo 2019 → 17.72 hrs abril 2019 → 7.26 hrs mayo 2019 → 8.69 hrs junio 2019 → 16.37 hrs
Producción de la línea		Aumento de la producción de hilos de cobre (toneladas) marzo 2019 → 6.327 t abril 2019 → 2.595 t mayo 2019 → 3.105 t junio 2019 → 5.842 t
Rentabilidad de la línea (ingresos adicionales)		marzo 2019 → S/17,112.15 abril 2019 → S/7,024.99 mayo 2019 → S/8,398.46 junio 2019 → S/15,783.71

*Nota:* Elaboración propia

De la Tabla 25, podemos observar que la red neuronal propuesta obtiene mejores predicciones que el experto encargado de las previsiones en la empresa puesto que el Error de pronóstico obtenido por la RNA es de 13,86% valor que es mucho menor comparado con el 37,08 % del experto, con esta información podemos realizar varias modificaciones

en la planificación y control de la producción como una mejoras en el plan de mantenimiento de la línea que se espera reducir los tiempos de Parada de la línea trefiladora A120 en un 30%.

Al disminuir las horas de parada de línea aumenta la producción, por ejemplo, para el mes de marzo la producción aumenta 6.327 tn, para abril aumenta 2.595 tn, para mayo 3.105 tn y para junio 5.842 tn. Calculando los montos recuperados de las paradas de línea de los meses mencionados asciende a S/48,319.31 soles como ingresos para la empresa en estudio.

**Cumplimiento del objetivo General:** Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial en la Planificación y Control de la Producción ya que, pronostica con más precisión los costos de parada de línea con un error de 13,86% con respecto al experto que es de 37,08 % , permitiendo con el tiempo de parada obtenido por la RNA, mejorar el plan de mantenimiento disminuyendo en un 30% el tiempo de parada de la línea, aumentando la producción en los meses de marzo, abril ,mayo y junio del 2019 en 17.869 toneladas, el cual representa un ingresos de S/48,319.31 generando una mayor rentabilidad para la empresa.

## CAPÍTULO V. DISCUSIÓN Y CONCLUSIONES

### 5.1. Discusión de resultados

*El resultado obtenido referente al objetivo específico 1*, La metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Se obtuvo unos resultados que demuestra que existe una mejora en el pronóstico de los costos de parada de línea, cuyo error (RNA) es 13.86% y el error del experto es 37.08 %; observando que el error cometido por la RNA es menor con respecto al monto real del costo de parada.

*El resultado obtenido referente al objetivo específico 2*, La metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Según los resultados obtenidos, se demuestra que existe una mejora con la aplicación de la metodología de Simulación con Inteligencia Artificial, porque al pronosticar los tiempos de parada de los meses futuros que son marzo, abril, mayo y junio del 2019, se puede proponer acciones correctivas como una propuesta de plan de mantenimiento autónomo que reduzca en un 30% los tiempos de parada de la línea.

*El resultado obtenido referente al objetivo específico 3*, La metodología de Simulación con Inteligencia Artificial ayuda a la producción de la línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Según los resultados obtenidos, se demuestra que existe una mejora en la producción ya que, al disminuir las horas de parada de línea con la propuesta del mantenimiento autónomo, se aumenta la producción para los meses de marzo en 6.327tn, para abril en 2.595tn, para mayo en 3.105tn y para junio en 5.842tn. del año 2019.

***El resultado obtenido referente al objetivo específico 4,*** La metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Según los resultados obtenidos, se demuestra que existe una mejora en la rentabilidad de la línea ya que, al disminuir las horas de parada de línea, aumenta la producción, generando ingresos adicionales en marzo con un monto de S/17,112.15, en abril de S/7,024.99, en mayo de S/8,398.46 y en junio de S/15,783.71 del 2019, los cuales suman un ingreso total de S/48,319.31.

***El resultado obtenido referente al objetivo General,*** La metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición. Según los resultados obtenidos, se demuestra que existe una mejora en la Planificación y Control de la Producción ya que, pronostica con más precisión los costos de parada de línea con un error de 13,86% con respecto al experto que es de 37,08 % , permitiendo con el tiempo de parada obtenido por la RNA, mejorar el plan de mantenimiento disminuyendo en un 30% el tiempo de parada de la línea, aumentando la producción en los meses de marzo, abril ,mayo y junio del 2019 en 17.869 toneladas, el cual representa un ingresos de S/48,319.31 generando una mayor rentabilidad para la empresa.



## 5.2. Conclusiones

**Primero:** Se puede utilizar una metodología con inteligencia artificial en el pronóstico de parada de línea, obteniendo resultados de pronóstico más preciso que sistemas informáticos o los procedimientos de los expertos, ya que el error de la RNA con respecto a los datos reales de las horas de parada de línea, obteniendo que el error de RNA es de 13.86% y el error del experto fue de 37.08%.

**Segundo:** Con la metodología de inteligencia artificial en el pronóstico de los tiempos de parada de línea, para los meses de marzo, abril, mayo y junio del 2019, se propone acciones correctivas como una propuesta de plan de mantenimiento autónomo que reduzca en un 30% los tiempos de parada de la línea.

**Tercero:** Con la metodología de inteligencia artificial en el pronóstico de los tiempos de parada de línea, se espera disminuir las horas de parada de línea con la propuesta del mantenimiento autónomo, el cual aumenta la producción para los meses de marzo en 6.327tn, para abril en 2.595tn, para mayo en 3.105tn y para junio en 5.842tn. del año 2019.

**Cuarto:** Al disminuir las horas de parada de línea con el mantenimiento autónomo, se aumenta la producción generando ingresos adicionales en marzo con un monto de S/17,112.15, en abril de S/7,024.99, en mayo de S/8,398.46 y en junio de S/15,783.71 del 2019, los cuales suman un ingreso total de S/48,319.31.

**Quinto:** Con la metodología de Inteligencia Artificial en la mejora de la Planificación y Control de la Producción, se pronosticó con más presión los costos de parada de línea con un error de 13,86% con respecto al experto que es de 37,08 % , luego con una propuesta de plan de mantenimiento autónomo se disminuye en un 30% el tiempo de parada de la línea, aumentando la producción en los meses de marzo, abril ,mayo y junio del 2019 en 17.869 toneladas, el cual representa un ingresos de S/48,319.31.

### 5.3. Recomendaciones

**Primero:** Se recomienda a la gerencia la utilización de la metodología con inteligencia artificial para el pronóstico de las paradas en las diferentes líneas de producción, ya que se demuestra que el error que presenta esta RNA es menor que los demás procedimientos utilizados por el área de planeación y control.

**Segundo:** Se recomienda a la gerencia que implemente el mantenimiento autónomo para lograr reducir los tiempos de parada de línea e incrementar la producción, lo cual genera más ingresos para la empresa, reflejado en el aumento del indicador eficiencia global de la línea.

**Tercero:** Se recomienda a la gerencia, la constante capacitación de los técnicos y operadores de la línea trefiladora

**Cuarto:** Se recomienda a la gerencia que utilice las nuevas tecnologías en la planeación y control de la producción.

**Quinto:** Se recomienda a la gerencia que capacite al personal del área de producción en la metodología de las 5S para mejorar los procesos de la planeación y control.

## REFERENCIAS

- Lasse Petteri, R. (2018). *Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro*. Editorial Planeta.
- Rivas Asanza, W. y Mazón Olivo, Bertha. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones*. Ediciones UTMACH
- Reinoso García, O., Jiménez García, I., Payá Castelló, L., Gil Aparicio, A. y Peidró Vidal, A. (2018). *MATLAB: conceptos básicos y descripción gráfica*. Universidad Miguel Hernández, 26.  
<https://books.google.es/books?hl=es&lr=&id=ioVxDwAAQBAJ&oi=fnd&pg=PR8&dq=matlab+libro&ots=G3h4q2ftQs&sig=1hyrU3MJ9ZftC3nhEuA4Dr4xL3w#v=onepage&q=matlab&f=false>
- Smith, J. (2017). *Neural Networks. Applications and Examples Using Matlab*. CreateSpace Independent Publishing
- Rivas Asanza, W. y Mazón Olivo, Bertha. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones*. Ediciones Utmach
- Viteri Moya, J. (2015). *Gestión de la producción con enfoque sistémico*. Cedeño Alcívar
- Yepes Piqueras, V. (2015). *Coste, producción y mantenimiento de maquinaria para la construcción*. Universidad Politécnica de Valencia. Recuperado de: [https://gdocu.upv.es/alfresco/service/api/node/content/workspace/SpacesStore/a45c7f07-26b1-4021-a580-116cb860481a/TOC\\_0402\\_04\\_01.pdf?guest=true](https://gdocu.upv.es/alfresco/service/api/node/content/workspace/SpacesStore/a45c7f07-26b1-4021-a580-116cb860481a/TOC_0402_04_01.pdf?guest=true)
- Eslava, J. (2013). *Curso esic de emprendimiento y gestión empresarial*. ESIC EDITORIAL
- Serrano, A., Soria, E., y Martin, J. (2010). *Redes Neuronales Artificiales*. Universidad Politécnica de Valencia. Recuperado de: [http://ocw.uv.es/ingenieria-y-arquitectura/1-2/libro\\_ocw\\_libro\\_de\\_redes.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-2/libro_ocw_libro_de_redes.pdf)
- Basogain Olabe, X. (2008). *Redes neuronales artificiales y Sus aplicaciones*. Escuela Superior de Ingeniería de Bilbao. Recuperado de [https://ocw.ehu.eus/pluginfile.php/40137/mod\\_resource/content/1/redes\\_neuro/contenidos/pdf/libro-del-curso.pdf](https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf)
- A. Boden, M. (2017). *Inteligencia Artificial*. Turner. Recuperado de: <https://es.scribd.com/read/364034791/Inteligencia-Artificial>

- García Serrano, A. (2012). *Inteligencia artificial. Fundamentos, práctica y aplicaciones*. RC Libros. Recuperado de: <https://books.google.com.pe/books?id=WDuqquRP70UC&printsec=frontcover&hl=es#v=onepage&q&f=false>
- Flórez López, R. y Miguel Fernández, J. (2008). *Las redes neuronales artificiales. Fundamentos teóricos y aplicaciones prácticas*. Netbiblo
- Serna M., E. (2017). *Desarrollo e innovación en ingeniería Segunda Edición*. Editorial Instituto Antioqueño de Investigación. Recuperado de: <https://docplayer.es/85728378-Editorial-iai-prof-edgar-serna-m-ed-desarrollo-e-innovacion-en-ingenieria-segunda-edicion.html>
- Moore, H. (2012). *MATLAB para ingenieros*. Editorial Pearson. Recuperado de: <http://dea.unsj.edu.ar/control2/matlab%20para%20ingenieros.pdf>
- Ciaburro, G. (2017). *MATLAB para aprendizaje automático*. Packt. Recuperado de: [https://subscription.packtpub.com/book/big\\_data\\_and\\_business\\_intelligence/9781788398435](https://subscription.packtpub.com/book/big_data_and_business_intelligence/9781788398435)
- Gonzales Moreno, F. (2014). *Mercadotecnia estratégica: teoría e impacto en las unidades de información*. Universidad Nacional Autónoma de México. Recuperado de: [http://ru.iibi.unam.mx/jspui/bitstream/IIBI\\_UNAM/L117/1/mercadotecnia\\_estrategica\\_ui.pdf](http://ru.iibi.unam.mx/jspui/bitstream/IIBI_UNAM/L117/1/mercadotecnia_estrategica_ui.pdf)
- Gregory Mankiw, N. (2012). *Principios de Economía*. Harvard University. Recuperado de: <http://ru.economia.unam.mx/74/1/Mankiw%20%20Principios%20de%20economia%2C%206ta%20Edicion.pdf>
- Paredes Roldán, J. (2001). *Planificación y control de la producción*. Universidad de Cuenca. Recuperado de: <http://biblioteca.clacso.edu.ar/Ecuador/diuc-ucuenca/20121115114754/teoria.pdf>
- Caba Villalobos, N., Chamorro Altahona, O. y Fontalvo Herrera, T. (2001). *Gestión de la Producción y las Operaciones*. Corporación para la Gestión del Conocimiento Asesores del 2000. Recuperado de: [https://biblioteca.utec.edu.sv/siab/virtual/elibros\\_internet/55847.pdf](https://biblioteca.utec.edu.sv/siab/virtual/elibros_internet/55847.pdf)
- Groover, M. (1997). *Fundamentos de manufactura moderna: materiales, procesos y sistemas*. Prentice hall hispanoamericana s.a.

- Cruz Chávez, P., Torres García, A., Cruz Chávez, G. y Juárez Mancilla, J. (2016). *Metodología para medir la rentabilidad de un proyecto de inversión: estudio de caso de agua*. 3C Empresa. Recuperado de: <https://dialnet.unirioja.es/descarga/articulo/5746482.pdf>
- Hernández Sampieri, R., Fernández Collado, C. y Baptista Lucio, P. (2014). Definición del alcance de la investigación que se realizará: exploratorio, descriptivo, correlacional o explicativo. (6 ed., págs. 88-101). México: McGraw-Hill.
- Sáez López, J. (2017). *Investigación educativa. Fundamentos teóricos, procesos y elementos prácticos (enfoque práctico con ejemplos. Esencial para tfg, tfm y tesis*. Editorial UNED. Recuperado de: [https://books.google.com.pe/books?id=c3CZDgAAQBAJ&printsec=frontcover&hl=es&source=gbg\\_ge\\_summary\\_r&cad=0#v=onepage&q&f=false](https://books.google.com.pe/books?id=c3CZDgAAQBAJ&printsec=frontcover&hl=es&source=gbg_ge_summary_r&cad=0#v=onepage&q&f=false)
- Peersman, G. (2014). *Sinopsis: Métodos de recolección y análisis de datos en la evaluación de Impacto, Síntesis metodológica n.º10*, Centro de Investigaciones de UNICEF, Florencia. Recuperado de: [https://www.betterevaluation.org/sites/default/files/Metodos\\_de\\_recoleccion\\_y\\_analisis\\_de\\_datos\\_SP.pdf](https://www.betterevaluation.org/sites/default/files/Metodos_de_recoleccion_y_analisis_de_datos_SP.pdf)
- López Roldán, P. y Fachelli, S. (2015). *Metodología de la investigación social cuantitativa* Universitat Autònoma de Barcelona, Barcelona. Recuperado de: [https://ddd.uab.cat/pub/caplli/2017/185163/metinvsoccua\\_cap2-4a2017.pdf](https://ddd.uab.cat/pub/caplli/2017/185163/metinvsoccua_cap2-4a2017.pdf)
- Posso Pacheco, R., Barba Miranda y, L. y Otáñez Enríquez, N. (2020). *El conductismo en la formación de los estudiantes universitarios*. <https://revistas.investigacion-upelipb.com/index.php/educare/article/view/1229/1229>
- Martínez, A. (8 de octubre de 2018). *MATLAB: conceptos básicos y descripción gráfica*. editorial.umh.es. <https://editorial.umh.es/2018/10/08/matlab-conceptos-basicos-y-descripcion-grafica/>
- Conexión esesan (17 de junio 2020). *Paradas industriales: cómo tener éxito en el mantenimiento productivo de planta*. esan.edu.pe. <https://www.esan.edu.pe/apuntes-empresariales/2020/06/paradas-industriales-como-tener-exito-en-el-mantenimiento-productivo-de-planta/>
- Experto GestioPolis.com (18 de diciembre 2002). *¿Qué es un pronóstico? Características y métodos*. gestipolis.com. <https://www.gestipolis.com/que-es-un-pronostico-caracteristicas-y-metodos/>

Rus Arias, E. (07 de octubre, 2020). Diagrama de Pareto. economipedia.com.  
<https://economipedia.com/definiciones/diagrama-de-pareto.html>

Diagrama de Ishikawa (22 de noviembre de 2015.). En *Wikipedia*.  
[https://es.wikipedia.org/wiki/Diagrama\\_de\\_Ishikawa](https://es.wikipedia.org/wiki/Diagrama_de_Ishikawa)

Sig consulting (junio de 2018). *Metodología de las 5s*. airport. Recuperado de:  
<https://www.limairport.com/esp/SiteAssets/Lists/Noticias/AllItems/Las%205S%20como%20herramienta%20de%20mejora%20continua.pdf>

González (2015), *Pronóstico de la demanda a través de una Red Neuronal Artificial Perceptrón Multicapa*. (Tesis de titulación. Universidad De Holguín, Holguín).  
Recuperado de: <https://repositorio.uho.edu.cu/xmlui/handle/uho/5334>

Nakajima, S. (1991). *Introducción al TPM: mantenimiento productivo total*. Productivity Press. España. Recuperado de:  
[https://nanopdf.com/download/mantenimiento-autonomo-mantenimiento-planificado\\_pdf](https://nanopdf.com/download/mantenimiento-autonomo-mantenimiento-planificado_pdf)

## ANEXOS

### ÍNDICE DE ANEXOS

Anexo 1. Matriz de consistencia – Coherencia – Parte 1 .....	96
Anexo 2. Programa de Metodología de Simulación con Inteligencia Artificial .....	98
Anexo 3. Datos del experto que realiza la simulación con fórmulas estadísticas. ....	103
Anexo 4. Formato de registro de tiempo de parada en la línea trefiladora.....	104
Anexo 5. Guía de observación de la línea trefiladora.....	106
Anexo 6. Procedimientos de la Aplicación de RNA para el pronóstico del costo de parada de la línea trefiladora .....	107
Anexo 7. Configuración de las 6 RNA para el pronóstico de costo de parada .....	145
Anexo 8. Configuración de la red seleccionada para el pronostico.....	146
Anexo 9. Regresión lineal resultante de la RNA seleccionada para el pronostico.....	147
Anexo 10. Evidencias fotográficas mantenimiento deficiente .....	148

## Anexo 1. Matriz de consistencia – Coherencia – Parte 1

**Título:** Metodología de Simulación con Inteligencia Artificial en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición

**Autor:** Percy Marcial Romero Ríos

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES
General	General	General	
¿Cómo una metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?	Determinar cómo una metodología de Simulación con Inteligencia Artificial permite ayudar en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición.	Existe una mejora con una Metodología de Simulación con Inteligencia Artificial en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	<b>Variable (X)</b> Metodología de Simulación con Inteligencia Artificial. <b>Variable (Y)</b> Planificación y Control de la Producción.
Específicos	Específicos	Específicos	
1 ¿Cómo una metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?	Determinar cómo una metodología de Simulación con Inteligencia Artificial pronostica los costos de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	Existe una mejora con una metodología de Simulación con Inteligencia Artificial en el pronóstico de los costos de parada de línea, en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	<b>Variable (X<sub>1</sub>)</b> Metodología de Simulación con Inteligencia Artificial. <b>Variable (Y<sub>1</sub>)</b> Pronóstico de costo de parada de línea
2 ¿Cómo una metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?	Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a disminuir el tiempo de parada de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a disminuir el tiempo de parada de línea, en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	<b>Variable (X<sub>3</sub>)</b> Metodología de Simulación con Inteligencia Artificial. <b>Variable (Y<sub>3</sub>)</b> Tiempo de parada de línea



**Anexo 1.** Matriz de consistencia – Coherencia – Parte 2

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES
Específicos	Específicos	Específicos	
3 ¿Cómo una metodología de Simulación con Inteligencia Artificial ayuda a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?	Determinar cómo una metodología de Simulación con Inteligencia Artificial ayuda a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a la producción de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	<b>Variable (X<sub>2</sub>)</b> Metodología de Simulación con Inteligencia Artificial.  <b>Variable (Y<sub>2</sub>)</b> Producción
4 ¿Como una metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición?	Determinar como una metodología de Simulación con Inteligencia Artificial ayuda a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	Existe una mejora con una metodología de Simulación con Inteligencia Artificial para ayudar a la rentabilidad de línea en la Planificación y Control de la Producción, en sistemas de Manufactura de Fundición	<b>Variable (X<sub>4</sub>)</b> Metodología de Simulación con Inteligencia Artificial.  <b>Variable (Y<sub>4</sub>)</b> Rentabilidad

**Fuente:** Elaboración propia

**Anexo 2.** Programa de Metodología de Simulación con Inteligencia Artificial**1. Presentación**

En la actualidad, el estudio de la planificación de la producción es de mayor importancia que en el pasado, ya que ha quedado demostrado que las empresas dedicadas al estudio sobre los procedimientos empleados en la gestión de la producción alcanzan un mayor beneficio económico y una superioridad competitiva.

Se presenta una metodología de ayuda alternativa para la mejora del proceso de planeación de la producción con redes neuronales artificiales (RNA). La información al respecto pone en evidencia un tiempo elevado por las paradas de línea, afectando a los indicadores de producción. Se espera una mejora de la planeación y control de la producción en la línea trefiladora de la empresa en estudio del rubro fundición, que nos permita aumentar el nivel de rendimiento, disponibilidad y confiabilidad operacional de las máquinas.

**2. Marco Normativo (Marco legal)**

Comisión Europea: Nueva normativa en materia de IA - 21 de abril de 2021

**3. Justificación del programa**

- a) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite pronosticar por ejemplo los costos de parada de la línea, por medio de un conjunto de herramientas y esto beneficia directamente a incrementar las utilidades de la empresa.
- b) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite aportar una ayuda en la toma de decisiones en el plan de producción, generando más producción en la línea y esto beneficia a los planificadores de la producción de la línea.
- c) El programa “Metodología de Simulación con Inteligencia Artificial”, es importante porque permite pronosticar el tiempo de parada de la línea provocados por las fallas

de los equipos que conforman y esto beneficia a los técnicos del área de mantenimiento que ya están prevenidos de las posibles fallas, el cual les permite realizar un plan más eficaz para mantener la línea de producción activa el mayor tiempo posible.

#### **4. Alcance del programa**

El presente programa de Metodología de Simulación con Inteligencia Artificial, en una empresa de fundición y metalmecánica, tiene como alcance la jurisdicción de Los Olivos-Lima, dicha investigación se realizó en el periodo desde enero 2018 hasta junio 2019

#### **5. Objetivos del programa**

- a) Describir los lineamientos de la metodología con RNA, planificación, ejecución, verificación, en sistemas de manufactura de fundición
- b) Describir los procedimientos de ejecución de la “Metodología de Simulación con Inteligencia Artificial”
- c) Elaborar una matriz de ejecución
- d) Describir los resultados a obtener

## 6. Lineamiento de la planificación, ejecución, verificación y acción de la

### “Metodología de Simulación con Inteligencia Artificial”

#### 6.1 Planificación

##### a) Línea de base (diagnóstico inicial)

###### Paso 1: Diagrama de Ishikawa de la línea

Se realiza un diagrama Ishikawa identificando las causas de las paradas de línea

###### Paso 2: Costo de parada de la línea

Se realiza el cálculo de cuánto cuesta o dejó de percibir la empresa por las horas de tiempo de inactividad de la línea o tiempo de parada, en el proceso de producción.

Cálculo del costo de parada de la línea o costo por inactividad.

$$\text{CPLM} = \text{THM} \times \text{PH} \times \text{P} \times \text{TC}$$

Donde:

**CPLM:** Costo de parada de línea mensual

**THM:** Total de horas de parada en el mes

## 6.2. Ejecución

### 6.2.1. Desarrollo de la Metodología de Simulación con Inteligencia Artificial

**Tabla 1**

*Pasos para el pronóstico del costo de parada de línea mediante RNA*

Pasos	Procedimiento
Paso 1: Construcción de la RNA base	La construcción de la red neuronal base se determinó a partir de los parámetros de entrada y salida de la red que corresponden a las variables influyentes.
Paso 2: Recopilación de datos Históricos	Se deben de elegir cuidadosamente las variables a emplear en la RNA, se trata es incluir en el modelo las variables predictoras.
Paso 3: Diseño de la Topología de la RNA	El tipo de red neuronal artificial que se va a utilizar es un perceptrón multicapa (MPL).
Paso 4: Normalización de los datos para la RNA	El proceso de normalización es necesario para uniformizar los datos.
Paso 5: Entrenamiento de la RNA del Costo de parada de línea CP	La fase de entrenamiento de una red neuronal sirve para asociar un patrón de entradas a un patrón de salidas
Paso 6: Validación de la RNA	En proceso de validación de las redes neuronales, valida las RNAs con datos existentes.
Paso 7: Selección de la RNA más exacta para el Pronóstico de CP	Se analiza las RNAs, de los cuales se toma como modelo la red simulada que presente el menor ECM, luego dicha red se usa para el pronóstico.
Paso 8: Datos obtenidos por el pronóstico de la RNA seleccionada	Se pronostica con la red seleccionada en el Matlab obteniendo datos que luego serán comparados con los datos reales para verificar la exactitud.

*Nota:* Elaboración propia

## 6.3. Verificación y acción

### 6.3.1. Indicadores de verificación y acción de la Metodología de Simulación con

#### Inteligencia Artificial

- c) Demostración mediante la herramienta Neural Networks de Matlab
- d) Demostración mediante el Procedimiento Analíticos

## 7. Matriz de Ejecución

**Tabla 2**

*Matriz de ejecución*

	Contexto	Herramienta Utilizada	Tiempo
1.1. Realizar normalización de datos históricos  (Romero Ríos Percy)	En gabinete	Ms Excel, calculadora	Semana 1
1.2. Creación de la red base, realizar los entrenamientos, validación, selección de la RNA y realizar el pronóstico  (Romero Ríos Percy)	En gabinete	Matlab	Semana 2, semana 3 y semana 4
1.3 Realización de la verificación de los datos generados por el pronóstico de la RNA  (Romero Ríos Percy)	En gabinete	Matlab	Semana 6
<i>Nota:</i> Elaboración propia			

## 8. Evaluación y acción

los indicadores de evaluación y acciones son:

**Tabla 3**

*Indicadores de evaluación y acciones*

<b>Variables a evaluar</b>	<b>indicador</b>
1) Planeación y control de la producción	1.1 Costo de parada línea 1.2 Tiempo de parada línea 1.3 Producción de línea
2) Rentabilidad	2.1. Utilidad 2.2. Ingresos

*Nota:* Elaboración propia

## 9. Presupuesto

Para realizar la investigación se utilizó los recursos de la empresa, como el uso de un equipo de cómputo que proporcione el área de mantenimiento y también se utilizó el equipo de cómputo de uso propio.

**Anexo 3.** Datos del experto que realiza la simulación con fórmulas estadísticas.

---

**Datos de experto**

---

**Nombre:****Área:** Mantenimiento**Objetivo:** Obtener las variables actuales con las que cuenta el experto para poder hallar la cantidad tiempo de parada de los equipos de la línea trefiladora a120 y poder añadir otras variables que se consideran necesarias según su experiencia.**Descripción:** Se mencionan las variables teóricas que han sido comprobadas mediante estudios técnicos, que influyen directamente en el pronóstico de productos generales y otras variables que se deben seleccionar igualmente puesto que son influyentes en el proceso de pronóstico de costo de parada, que son consideradas aptas para tomarse en cuenta.**Fecha:** 28/10/2019*Nota:* Proporcionado por la empresa**Anexo 4.** Formato de registro de tiempo de parada en la línea trefiladora



<b>RUTINAS DE MANTENIMIENTO DE LINEA TREFILADORA</b>								
<b>MANTENIMIENTO</b>								
<b>LINEA:</b>				<b>SEVICIO:</b>				
<b>MARCA:</b>								
<b>MODELO:</b>								
<b>SERIE:</b>				<b>AMBIENTE:</b>				
<b>N° INV TECNICO:</b>								
<b>ID:</b>								
Fallas	Entrada	Salida	Horas	Hr. Parada	Área	Motivo	Esquipo	Sub-equipo
1								
2								
3								
4								
5								
6								
7								
8								
9								
10								
11								
12								
<p><b>Fecha de realización:</b></p> <p><b>Código de técnico:</b></p> <p><b>Firma del técnico:</b></p> <p><b>Tiempo de ejecución:</b></p> <p><i>Recomendaciones:</i></p> <p><i>*Completar la ejecución de la rutina con el manual del fabricante.</i></p> <p><i>*Revisar el número de inventario de insumos.</i></p> <p><i>*Siempre complete toda la información.</i></p>								

Fuente: Proporcionada por la empresa

**Anexo 5.** Guía de observación de la línea trefiladora

<b>GUÍA DE OBSERVACIÓN</b>				
<b>ELEMENTO A OBSERVAR</b>	<b>ESTADO</b>			<b>OBSERVACIONES</b>
	<b>BUENO</b>	<b>REGULAR</b>	<b>MALO</b>	

Fuente: Proporcionado por la empresa

## **Anexo 6. Procedimientos de la Aplicación de RNA para el pronóstico del costo de parada de la línea trefiladora**

### **Desarrollo de la Metodología de Simulación con Inteligencia Artificial**

Paso 1: Construcción de la RNA base

Paso 2: Recopilación de datos Históricos

Paso 3: Diseño de la Topología de la RNA

Paso 4: Normalización de los datos para la RNA

Paso 5: Entrenamiento de la RNA del Costo de parada de línea CP

Paso 6: Validación de la RNA

Paso 7: Selección de la RNA más exacta para el Pronóstico de CP

Paso 8: Datos pronosticados por la RNA seleccionada

### **Pasos para desarrollo de la metodología de RNA para el pronóstico de parada de línea**

#### **Paso 1: Construcción de la RNA base**

La construcción de la red neuronal base se determinó a partir de los parámetros de entrada y salida de la red que corresponden a las variables influyentes en el mantenimiento de los equipos de la línea trefiladora, como los tiempos de parada e los equipo, el costo de parada de línea, y las horas programadas de producción en la línea trefiladora A120. La topología de la red fue obtenida mediante procesos de prueba y error para hallar los valores más adecuados del número de capas ocultas, tipo de red, número de neuronas por cada capa, etc.

#### **Paso 2: Recopilación de datos Históricos**

Se deben de elegir cuidadosamente las variables a emplear en la RNA, se trata es incluir en el modelo las variables predictoras que realmente pronostiquen la variable dependiente. La introducción de variables irrelevantes puede provocar un sobreajuste innecesario en el modelo (Palmer, 2005). De acuerdo a lo explicado, se seleccionó un conjunto de variables que permitirán evaluar diferentes aspectos influyentes en el pronóstico o simulación de la demanda de tiempo que toma el mantenimiento de los

equipos de la línea trefiladora A120.

Las variables de entrada son los parámetros que afectan al desempeño de la RNA y que a continuación se muestran en la Tabla 1.

**Tabla 1**

*Variables de entrada.*

Variable	Descripción	Tipo	Codificación
<b>M</b>	Mes	<i>Enero</i>	<i>1</i>
		<i>Febrero</i>	<i>2</i>
		<i>Marzo</i>	<i>3</i>
		<i>Abril</i>	<i>4</i>
		<i>Mayo</i>	<i>5</i>
		<i>Junio</i>	<i>6</i>
		<i>Julio</i>	<i>7</i>
		<i>Agosto</i>	<i>8</i>
		<i>Septiembre</i>	<i>9</i>
		<i>Octubre</i>	<i>10</i>
		<i>Noviembre</i>	<i>11</i>
		<i>Diciembre</i>	<i>12</i>
<b>FPG</b>	Tiempo falla Polines guía	<i>horas</i>	<i>Numero decimal</i>
<b>FSE</b>	Tiempo falla Sistema eléctrico	<i>horas</i>	<i>Numero decimal</i>
<b>FSM</b>	Tiempo de falla Sistema Mecánico	<i>horas</i>	<i>Numero decimal</i>
<b>FSG</b>	Tiempo de falla Sistema Giro	<i>horas</i>	<i>Numero decimal</i>
<b>FO</b>	Tiempo de falla otros	<i>horas</i>	<i>Numero decimal</i>
<b>HP</b>	Tiempo en horas de producción de la línea trefiladora x mes	<i>horas</i>	<i>Numero decimal</i>

*Nota:* Elaboración propia


El propósito fue pronosticar o simular los costos de inactividad de la línea trefiladora A120 producidos mensualmente por las fallas de sus equipos internos, por lo cual en el problema

se buscó pronosticar la variable de salida  $Y_i$  equivalente a el costo de parada de línea o inactividad de la línea trefiladora mensualmente.

**$Y_i$  = Costo producido por tiempo de parada de línea trefiladora**

### **Paso 3: Diseño de la Topología de la RNA**

El tipo de red neuronal artificial que se va a utilizar es un perceptrón multicapa (MPL), el cual está justificado. El diseño que se muestra en la Figura 1. Fue elaborado en MATLAB, el cual muestra la red neuronal que consta de cuatro capas (1 de entrada, 2 ocultas y 1 de salida).




**Figura 1.** Diseño de la topología de la RNA

*Fuente:* elaboración propia

La topología de la RNA propuesta tiene las siguientes características:

- a) **Tipo de red:** Red multicapa unidireccional o perceptrón multicapa (MPL), es decir una red con conexiones que pasan las salidas en una única dirección a neuronas de la siguiente capa.
- b) **Número de neuronas en la capa de entrada:** 7, valor considerado de acuerdo a las variables de entrada.
- c) **Número de capas ocultas:** 2, valor determinado por prueba y error.
- d) **Número de neuronas en la capa oculta:** 5. valor hallado mediante las pruebas en el entrenamiento de la red que se muestra en el desarrollo del proceso.
- e) **Número de neuronas en la capa de Salida:** 1, valor establecido de acuerdo a la variable de salida que es  $Y_i$ .

f) **Algoritmo de aprendizaje y validación:** Backpropagation.



**Figura 2.** Arquitectura de la RNA para pronosticar el costo de parada de la línea trefiladora

*Fuente:* elaboración propia

#### **Paso 4: Normalización de los datos para la RNA**

En el trabajo de investigación se utilizó los datos históricos de los tiempos de parada de la línea trefiladora, especificando que los datos de entrenamiento constan desde enero del 2018 hasta febrero del 2019 y los datos de validación son marzo, abril, mayo y junio del año 2019.

**Tabla 2**

*Datos históricos de los tiempos de parada de la línea trefiladora A120*

Mes	Nº mes	Polines guías de coiller (hrs)	Sistema eléctrico / cambio de motor(hrs)	Sistem a mecáni co coiller (hrs)	Sistema tran- mec giro plataforma (hrs)	Otras fallas( hrs)	Horas de producción programada s(hrs)	Costo de las horas paradas de la línea trefiladora
Ene-2018	1	9.03	0.00	1.92	1.87	3.50	592.00	S/36,738.59
Feb-2018	2	1.18	0.00	4.23	0.00	0.00	569.00	S/12,196.16
Mar-2018	3	13.70	1.17	0.82	0.00	0.00	571.00	S/35,312.58
Abr-2018	4	1.67	0.00	4.80	0.00	0.00	560.00	S/14,560.34
May-2018	5	10.62	0.00	5.20	2.12	7.67	596.00	S/57,640.93
Jun-2018	6	13.15	1.08	0.25	0.00	0.00	574.00	S/32,610.66
Jul-2018	7	8.70	0.50	0.45	0.23	5.23	580.00	S/34,021.66
Ago-2018	8	2.50	0.80	0.90	1.56	4.56	595.00	S/23,236.50
Set-2018	9	10.05	1.20	2.30	0.25	6.80	593.00	S/46,382.94
Oct-2018	10	1.87	0.85	1.85	0.00	3.85	586.00	S/18,958.46
Nov-2018	11	8.50	0.60	0.30	1.70	0.00	567.00	S/24,992.75
Dic-2018	12	9.60	0.00	3.80	1.10	5.20	562.00	S/44,356.50
Ene-2019	1	7.20	0.30	2.10	0.00	5.26	580.00	S/33,458.76
Feb-2019	2	3.30	0.90	0.78	0.96	6.50	595.00	S/28,009.89
Mar-2019	3	11.50	1.30	4.52	1.56	4.23	593.00	S/52,034.45
Abr-2019	4	2.30	1.08	1.23	0.00	2.96	586.00	S/17,044.60
May-2019	5	11.60	0.00	0.85	0.52	0.00	567.00	S/29,203.24
Jun-2019	6	12.60	1.10	0.56	0.95	4.90	562.00	S/45,279.66

*Nota:* Elaboración propia

### Datos para la validación

**Tabla 3**

*Datos de entrada para la validación de la RNA.*

M	FPG	FSE	FSM	FSG	FO	HP	Yi	
Mes	Nº Mes	Poline s guías de coiller (hrs)	Sistema eléctrico / cambio de motor(hrs)	Sistema mecáni co coiller( hrs)	Sistema tran- mec giro plataform a (hrs)	Otras fallas (hrs)	Horas de producci ón program adas(hrs )	Costo de las horas paradas de la línea trefiladora
Mar-2019	3	11.50	1.30	4.52	1.56	4.23	593.00	S/52,034.45
Abr-2019	4	2.30	1.08	1.23	0.00	2.96	586.00	S/17,044.60
May-2019	5	11.60	0.00	0.85	0.52	0.00	567.00	S/29,203.24
Jun-2019	6	12.60	1.10	0.56	0.95	4.90	562.00	S/45,279.66

*Nota:* Elaboración propia

El proceso de normalización fue necesario para nuestro trabajo de investigación puesto que se desea uniformizar los datos ya que las unidades de cada variable son disímiles (por ejemplo, las unidades de los costos de parada de línea son demasiado altas a comparación



de las unidades del resto de variables) y se diferencian de manera notable. Con este proceso de normalización se logra obtener valores uniformes de entrada en un rango de 0-1 para que no se produzca dependencias de alguna de las variables para alcanzar el resultado ya que cada una de ellas influye en el pronóstico.

Este proceso se realizó a partir de la división de todos los datos de una variable entre el mayor de los mismos.

$$D_n = D_i / MD$$

$D_n$  = Dato Normalizado

$D_i$  = Variable de entrada  $i$

$MD$  = Valor máximo de la variable de entrada

A continuación, se muestran un ejemplo de normalización

#### **Normalizando la variable FPG (tiempo de falla en los Polines de Guía)**

$MD=13.70$ : Representa el mayor valor de la variable FPG de los datos de toda la muestra

$FPG1=9.03$ : Representa el valor a normalizar, que corresponde al mes de enero.

$D_n=9.03/13.70= 0.66$ : Resultado de la normalización.

El valor normalizado para la variable FPG1 con el dato 9.03 es 0.66

La normalización de los datos de entrada se llevó a cabo de forma similar para los datos de las variables de entrenamiento y validación.

#### **Tabla 4**

*Normalización de datos de entrada para el entrenamiento*

	<b>M</b>	<b>FPG</b>	<b>FSE</b>	<b>FSM</b>	<b>FSG</b>	<b>FO</b>	<b>HP</b>	<b>Yi</b>
Ene-2018	0.0833	0.6594	0.0000	0.3686	0.8819	0.4565	0.9933	0.6374
Feb-2018	0.1667	0.0864	0.0000	0.8141	0.0000	0.0000	0.9547	0.2116
Mar-2018	0.2500	1.0000	0.8974	0.1571	0.0000	0.0000	0.9581	0.6126
Abr-2018	0.3333	0.1217	0.0000	0.9231	0.0000	0.0000	0.9396	0.2526
May-2018	0.4167	0.7749	0.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Jun-2018	0.5000	0.9599	0.8333	0.0481	0.0000	0.0000	0.9631	0.5658
Jul-2018	0.5833	0.6350	0.3846	0.0865	0.1087	0.6822	0.9732	0.5902
Ago-2018	0.6667	0.1825	0.6154	0.1731	0.7370	0.5948	0.9983	0.4031
Set-2018	0.7500	0.7336	0.9231	0.4423	0.1181	0.8870	0.9950	0.8047
Oct-2018	0.8333	0.1365	0.6538	0.3558	0.0000	0.5022	0.9832	0.3289
Nov-2018	0.9167	0.6204	0.4615	0.0577	0.8031	0.0000	0.9513	0.4336
Dic-2018	1.0000	0.7007	0.0000	0.7308	0.5197	0.6783	0.9430	0.7695
Ene-2019	0.0833	0.5255	0.2308	0.4038	0.0000	0.6861	0.9732	0.5805
Feb-2019	0.1667	0.2409	0.6923	0.1500	0.4535	0.8478	0.9983	0.4859

*Nota:* Elaboración propia

**Tabla 5**

*Normalización de datos para la validación validación*

	<b>M</b>	<b>FPG</b>	<b>FSE</b>	<b>FSM</b>	<b>FSG</b>	<b>FO</b>	<b>HP</b>	<b>Yi</b>
Mar-2019	0.2500	0.8394	1.0000	0.8692	0.7370	0.5517	0.9950	0.9027
Abr-2019	0.3333	0.1679	0.8308	0.2365	0.0000	0.3861	0.9832	0.2957
May-2019	0.4167	0.8467	0.0000	0.1635	0.2457	0.0000	0.9513	0.5066
Jun-2019	0.5000	0.9197	0.8462	0.1077	0.4488	0.6391	0.9430	0.7855

*Nota:* Elaboración propia

### **Paso 5: Entrenamiento de la RNA del Costo de parada de línea CP**

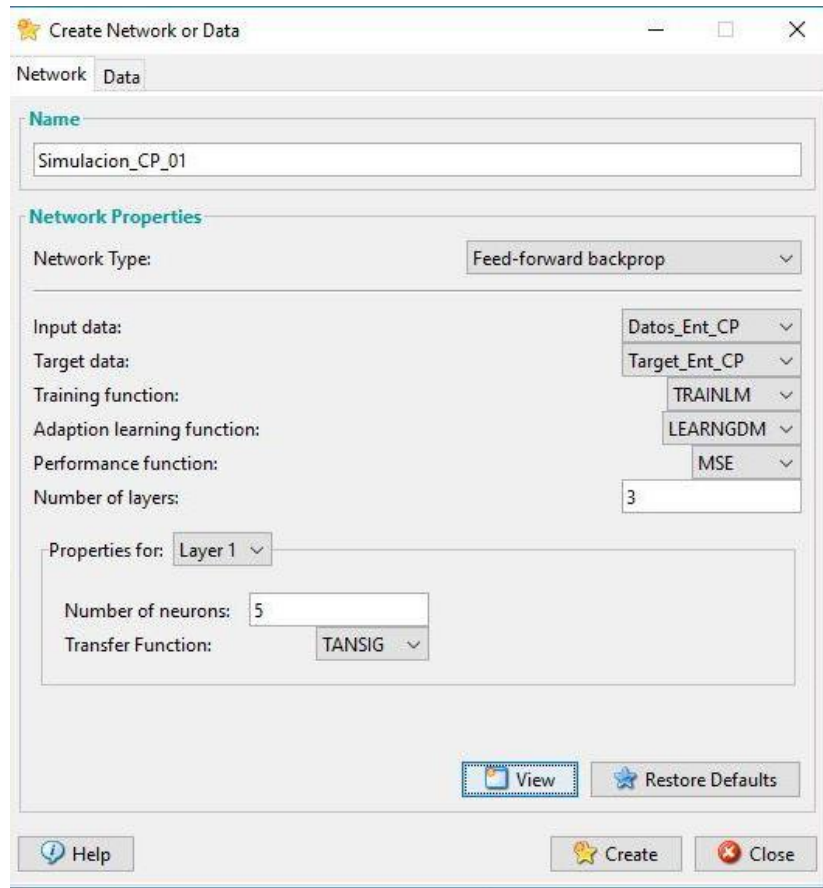
La etapa de entrenamiento de la RNA sirve para relacionar un patrón de entradas a un patrón de salidas de manera que la RNA pueda aprender a pronosticar de forma casi exacta el costo de parada de línea de acuerdo al correcto mapeo y conocimiento almacenado (configuración de pesos y bias).

En el proceso de entrenamiento de las redes neuronales se realizó usando las funciones del Neural Networks de la Caja de Herramientas del Matlab, las cuales diseñaron varias configuraciones que constan de diferentes algoritmos de aprendizaje, también como la variación de los parámetros. En consecuencia, se detalla las configuraciones de las RNAs pronosticadoras para el costo de parada de línea trefiladora A120.

A continuación, se mostrarán 6 redes que fueron creadas y entrenadas cada cual con distintos parámetros en cada fase y se mostrarán sus respectivos errores, los cuales nos servirán para elegir la red más adecuada para el pronóstico del CP. Cada configuración define las funciones utilizadas, los parámetros especificados, el esquema de red obtenido, la configuración de los pesos y el rendimiento alcanzado.

## Configuración 1

**SIMULACION\_CP\_01.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 3.** Configuración de la red Simulacion\_CP\_01

*Fuente:* elaboración propia

### a) Método

El método utilizado se basa en la creación de una red neuronal backpropagation haciendo uso del entorno del Matlab Neural Networks (nntool) que es la herramienta ideal para la elaboración de redes neuronales. La herramienta tiene las funciones especializadas para la configuración de cualquier tipo de RNA.

## b) Descripción

La RNA creada tiene la siguiente configuración:

**Tipo de red:** backpropagation

**Rango de las entradas:** 0 y 1

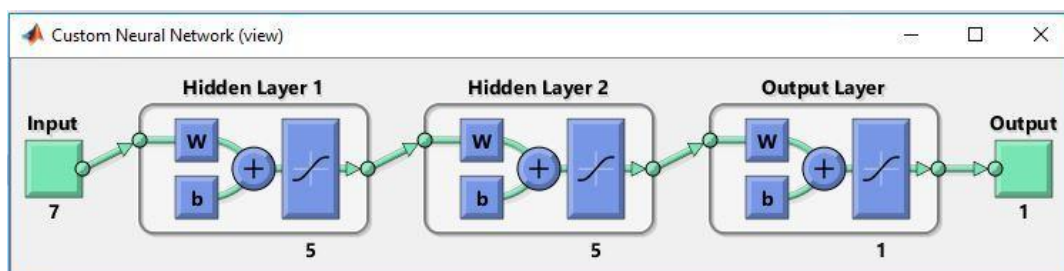
**Función de Entrenamiento:** TRAINLM, función que actualiza los pesos y las ganancias conforme a la optimización de Levenberg-Marquardt.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de Gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, Función de rendimiento que se basa en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) capa de entrada reconocida automáticamente por el MATLAB.

**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 5 neuronas en cada capa oculta y una neurona en la capa de salida.

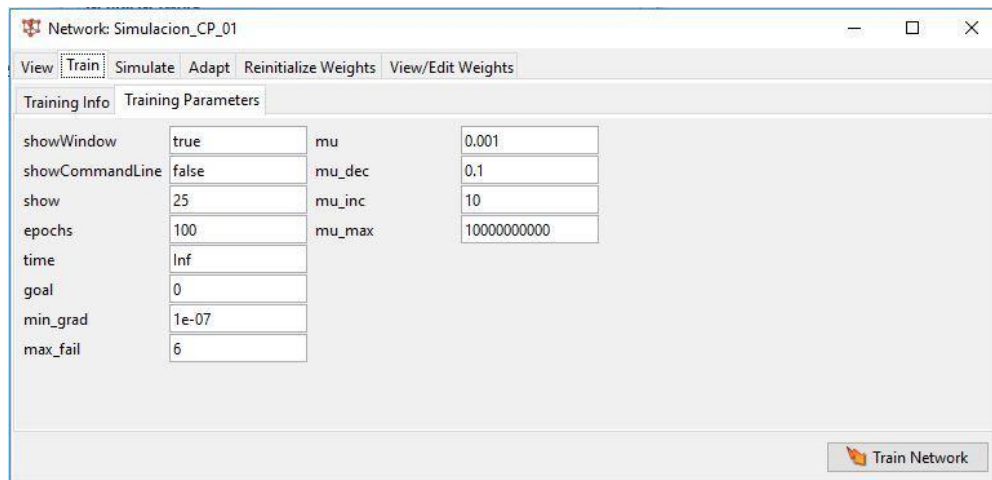


**Figura 4.** Esquema de la red neuronal Simulador\_CP\_01

*Fuente:* elaboración propia

**Propiedades de las capas:** ambas capas utilizan la función Tansig. función de transferencia sigmoidea tangente e hiperbólica.

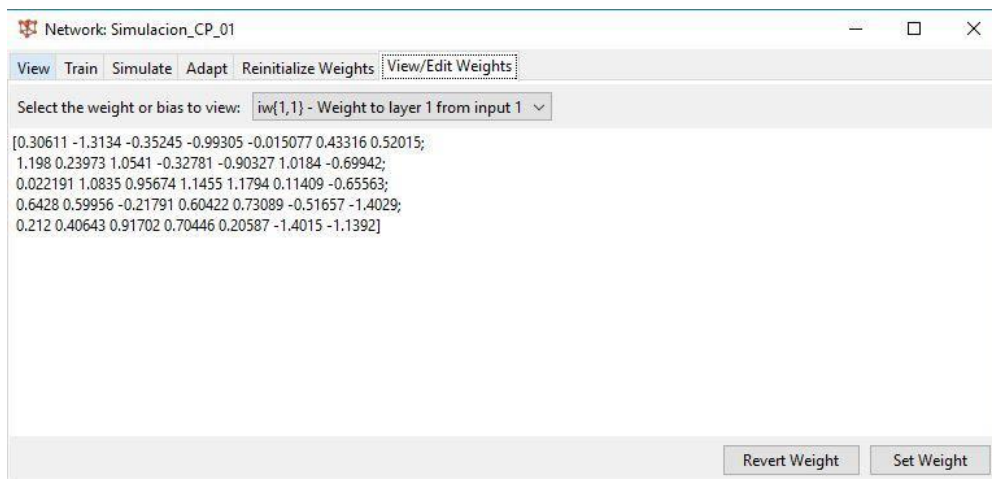
**Parámetros:** Los parámetros de la RNA se muestran en la ventana nntool



**Figura 5.** Configuración de parámetros para la RNA

*Fuente:* elaboración propia

**Configuración de pesos:** Los pesos hallados de la red se muestra ventana Neural Networks



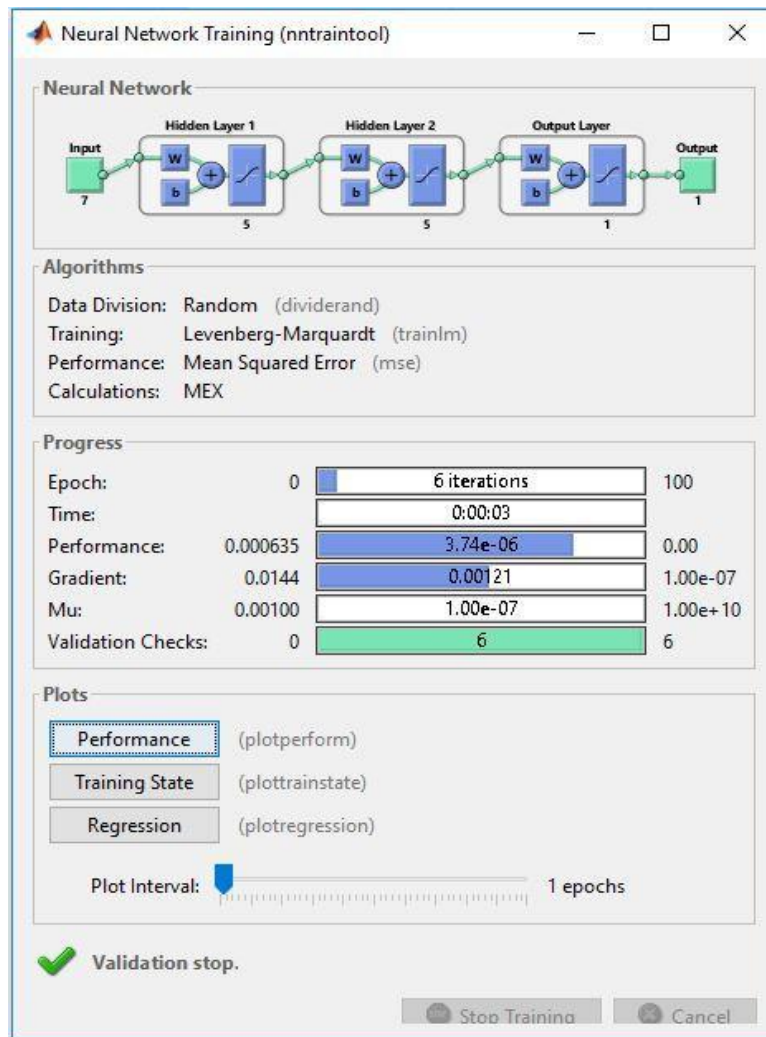
**Figura 6.** Pesos de la RNA Simulador\_CP\_01

*Fuente:* elaboración propia

**c) Resultado**

El resultado mostrado en el entrenamiento, es el performance que utiliza la función del error cuadrático medio que se muestra a continuación:

Error  $\rightarrow 0.000635$

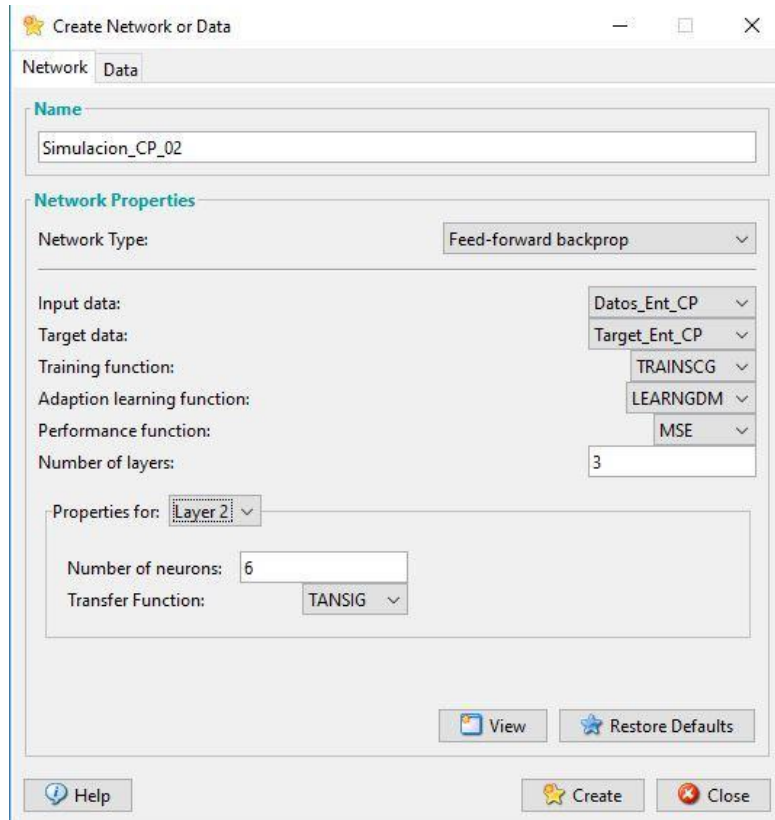


**Figura 7.** Entrenamiento realizado por la red Simulador\_Cp\_01

*Fuente:* elaboración propia

## Configuración 2

**SIMULACION\_CP\_02.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 8.** Configuración de la red Simulador\_Cp\_02

*Fuente:* elaboración propia

### a) Método

El método utilizado se basa en la creación de la RNA backpropagation creada bajo el entorno del Matlab Neural Networks (nntool).

### b) Descripción

La RNA creada tiene la siguiente configuración:

**Tipo de red:** backpropagation

**Rango de las entradas:** 0 y 1




**Función de Entrenamiento:** TRAINSCG función que renueva los pesos y valores de los bias mediante el método retropropagación de gradiente conjugado escalado.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, es la función de rendimiento fundado en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) capa de entrada reconocida automáticamente por el MATLAB.

**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 6 neuronas en cada capa oculta y una neurona en la capa de salida.

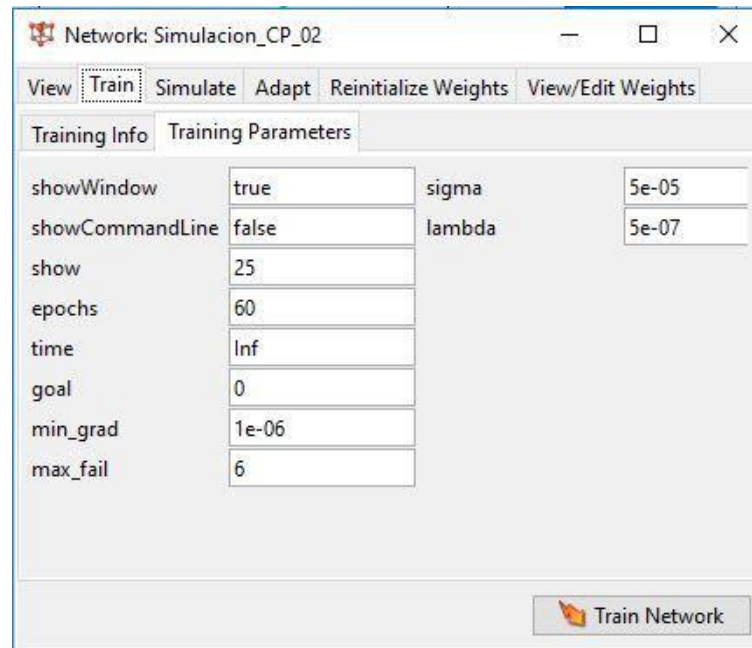


**Figura 9.** Esquema de la red neuronal Simulador\_Cp\_02

*Fuente:* elaboración propia

**Propiedades de las capas:** las ambas capas utilizan la función Tansig. función de transferencia sigmoidea tangente e hiperbólica.

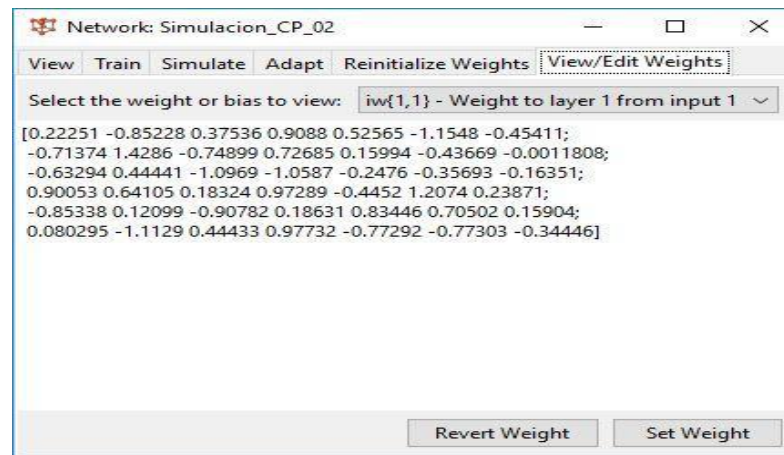
**Parámetros:** Los parámetros de la RNA que se muestran en la ventana nntool.



**Figura 10.** Parámetros solicitados por la RNA Simulador\_Cp\_02

*Fuente:* elaboración propia

**Configuración de pesos:** Los pesos hallados de la red se muestran en la ventana Neural Networks.



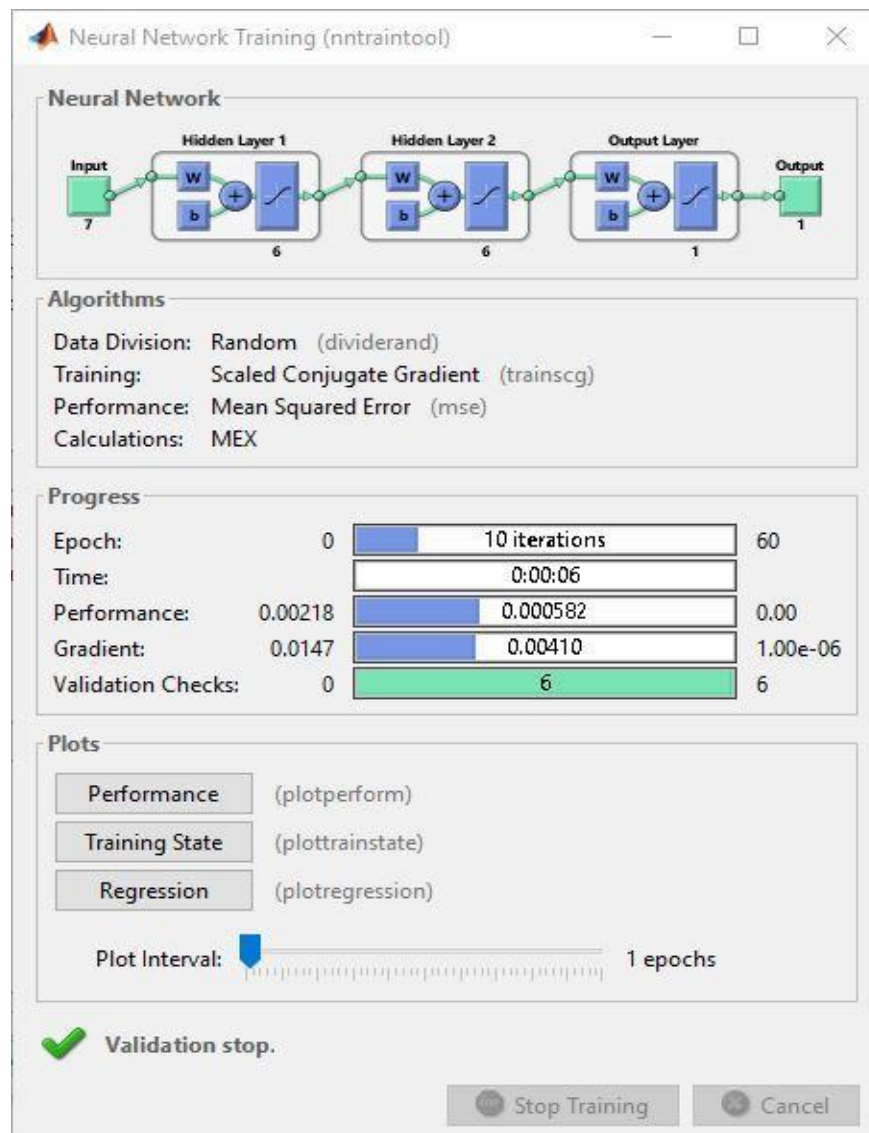
**Figura 11.** Pesos de la RNA Simulador\_Cp\_02

*Fuente:* elaboración propia

## Resultado

El resultado mostrado en el entrenamiento es el performance que usa la función del error cuadrático medio que se muestra a continuación:

**Error**→ 0.00218

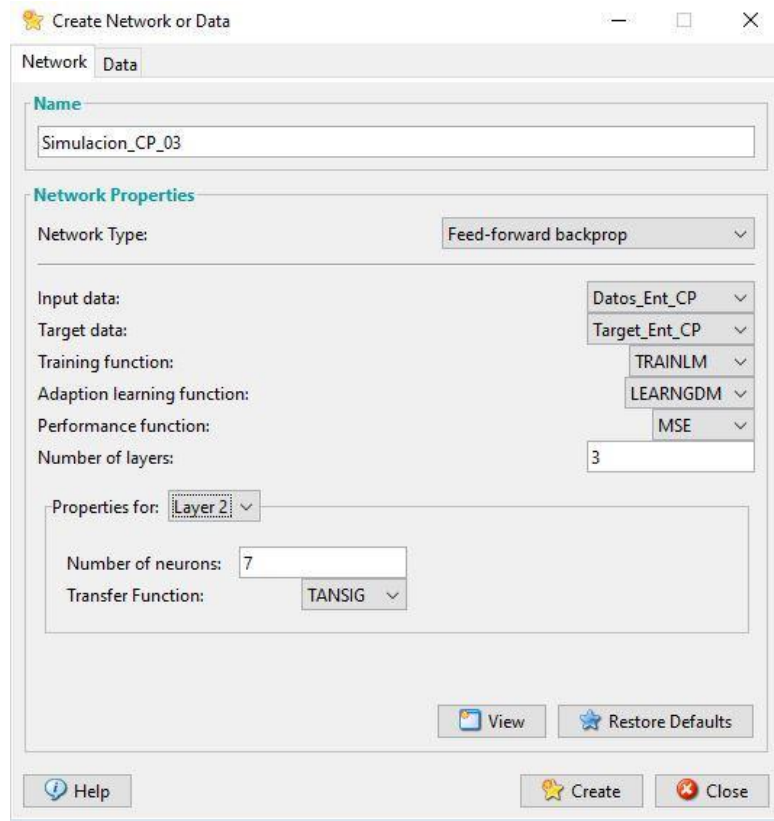


**Figura 12.** Entrenamiento realizado por la red Simulador\_Cp\_02

*Fuente:* elaboración propia

### Configuración 3

**SIMULACION\_CP\_03.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 13.** Configuración de la red Simulacion\_CP\_03

*Fuente:* elaboración propia

#### a) Método

El método utilizado se basa en la creación de la RNA backpropagation creada bajo el entorno del Matlab Neural Networks (nntool).

#### b) Descripción

La RNA creada muestran las siguientes características:

**Tipo de red:** backpropagation

**Rango de las entradas:** 0 y 1


**Función de Entrenamiento:** TRAINLM, función que renueva los pesos y las ganancias mediante la optimización de Levenberg-Marquardt.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, la función de rendimiento utiliza en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) capa de entrada reconocida automáticamente por el MATLAB.

**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida.

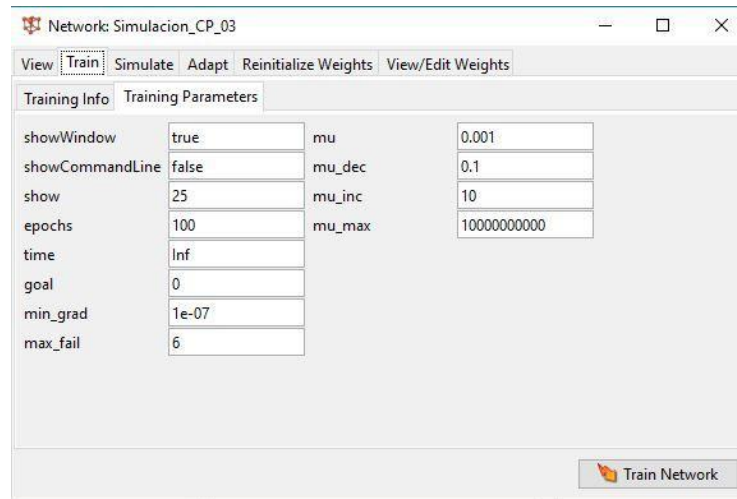


**Figura 14.** Esquema de la red neuronal Simulador\_CP\_03

*Fuente:* elaboración propia

**Propiedades de las capas:** las capas hacen el uso de la función Tansig, es una función de transferencia sigmoidea tangente e hiperbólica.

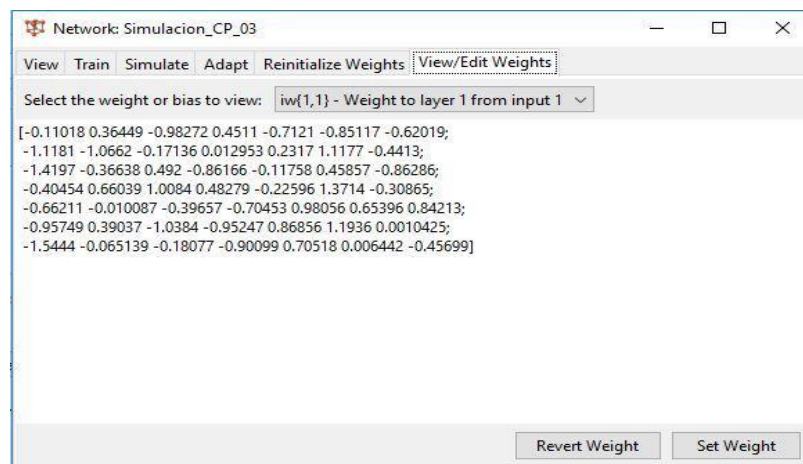
**Parámetros:** Los parámetros de la RNA se muestran en la ventana nntool.



**Figura 15.** Parámetros solicitados por la RNA Simulador\_Cp\_03

*Fuente:* elaboración propia

**Configuración de pesos:** Los pesos hallados de la red se muestran en la ventana Neural Networks.



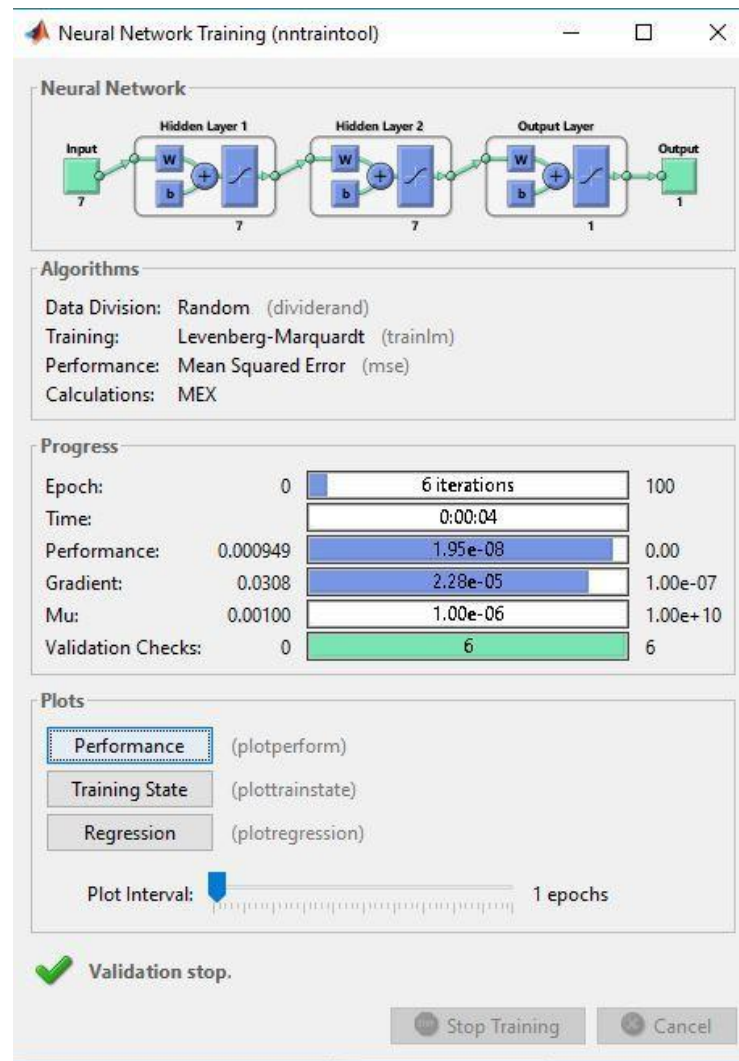
**Figura 16.** Pesos de la RNA Simulador\_CP\_03

*Fuente:* elaboración propia

### c) **Resultado**

El resultado que nos muestra el entrenamiento es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

Error→ 0.000949



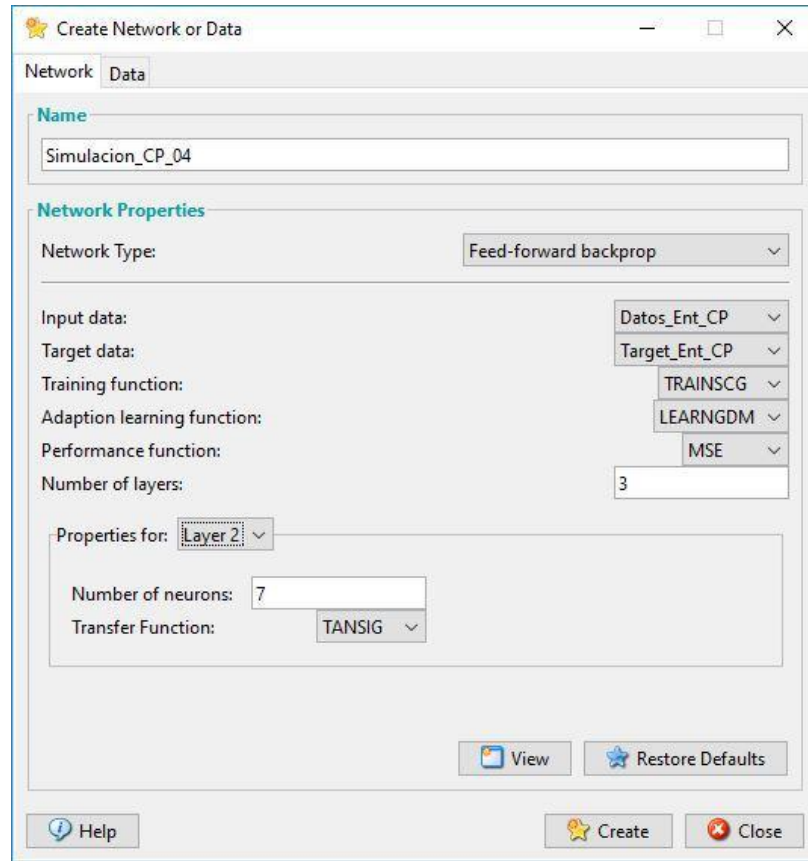
**Figura 17.** Entrenamiento realizado por la red Simulador\_Cp\_03

*Fuente:* elaboración propia



## Configuración 4

**SIMULACION\_CP\_04.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 18.** Configuración de la red Simulador\_Cp\_04

*Fuente:* elaboración propia

### a) Método

El método utilizado se basa en la creación de la RNA backpropagation creado bajo el entorno del Matlab Neural Networks (nntool).

### b) Descripción

La RNA creada muestra la siguientes características:

**Tipo de red:** backpropagation

**Rango de las entradas:** 0 y 1



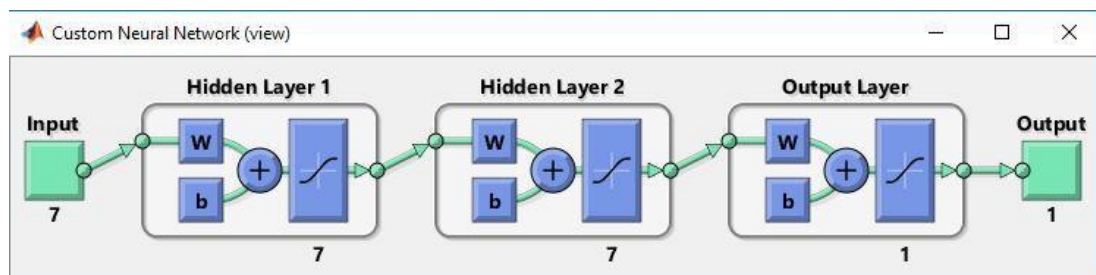
**Función de Entrenamiento:** TRAINSCG función que renueva los pesos y valores de los bias mediante el método retropropagación de gradiente conjugado escalado.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, La función de rendimiento se basa en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) capa de entrada reconocida automáticamente por el MATLAB.

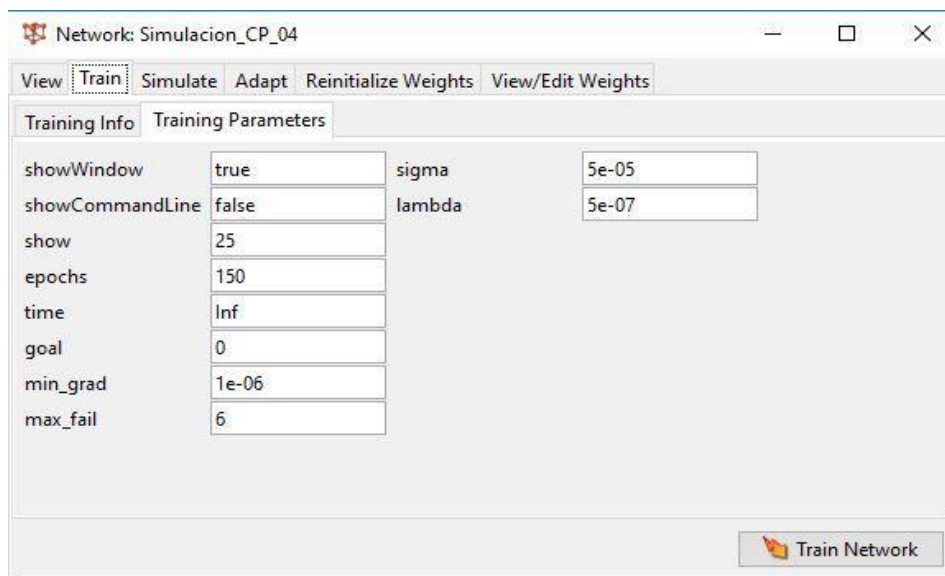
**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida.



**Figura 19.** Esquema de la red neuronal Simulador\_Cp\_04

*Fuente:* elaboración propia

**Propiedades de las capas:** las capas utilizan la función Tansig, función de transferencia sigmoidea tangente e hiperbólica.

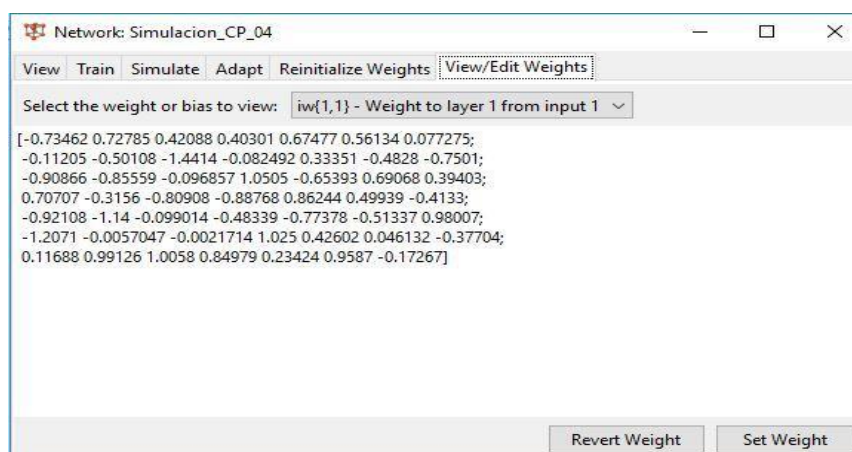


**Figura 20.** Parámetros solicitados por la RNA Simulador\_Cp\_04

*Fuente:* elaboración propia

**Parámetros:** Los parámetros de la RNA se muestran en la ventana nntool.

**Configuración de pesos:** Los pesos hallados de la red se muestran en la ventana Neural Networks.



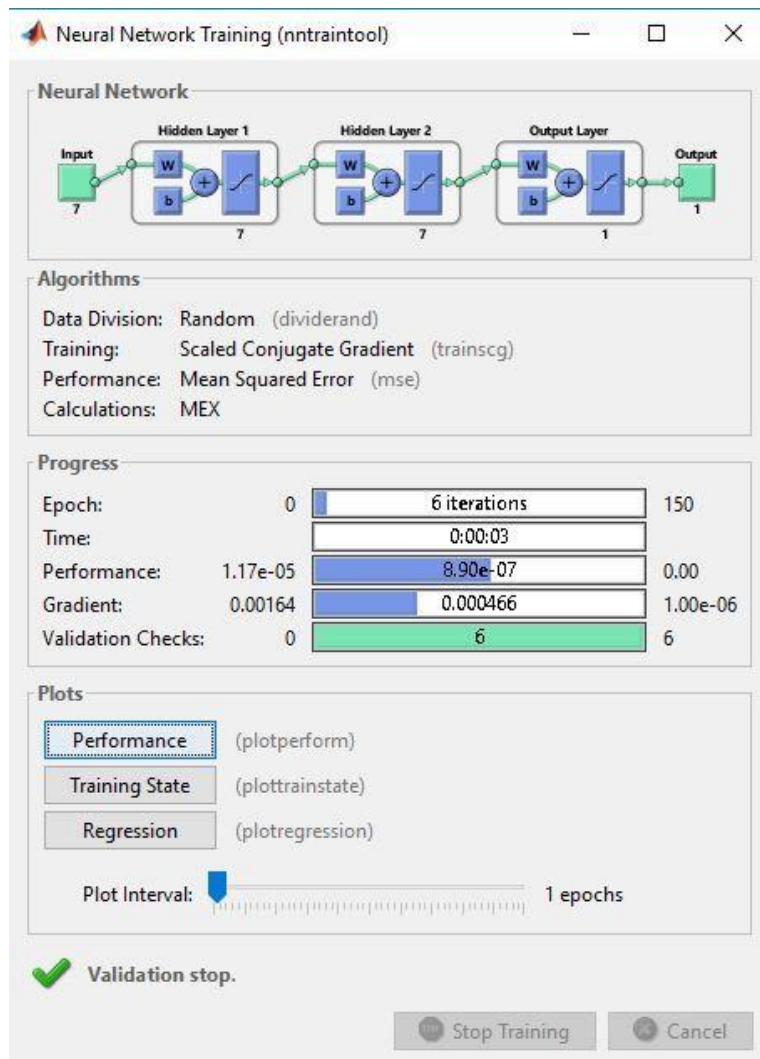
**Figura 21.** Pesos de la RNA Simulador\_Cp\_04

*Fuente:* elaboración propia

**c) Resultado**

El resultado mostrado en el entrenamiento es el performance que usa la función del error cuadrático medio que se muestra a continuación

**Error**→ 0.0000117

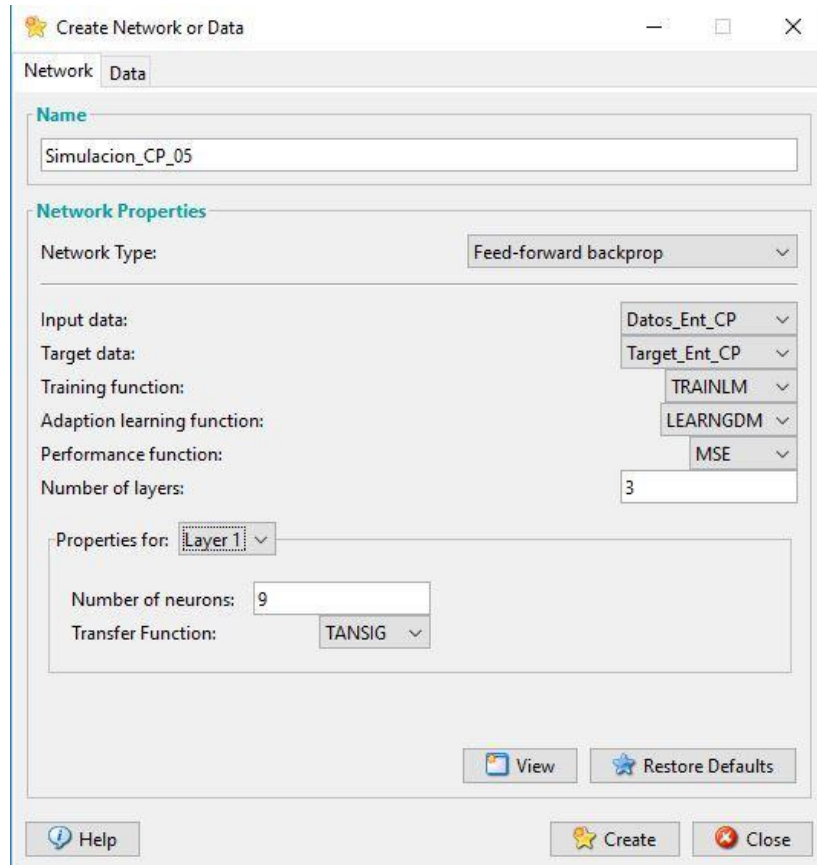


**Figura 22.** Entrenamiento realizado por la red Simulador\_Cp\_04

*Fuente:* elaboración propia

## Configuración 5

**SIMULACION\_CP\_05.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 23.** Configuración de la red Simulacion\_CP\_05

*Fuente:* elaboración propia

### a) Método

El método utilizado se basa en la creación de la RNA backpropagation creada bajo el entorno del Matlab Neural Networks (nntool).

### b) Descripción

La RNA creada muestra la siguiente característica:

**Tipo de red:** backpropagation

**Rango de las entradas:** 0 y 1

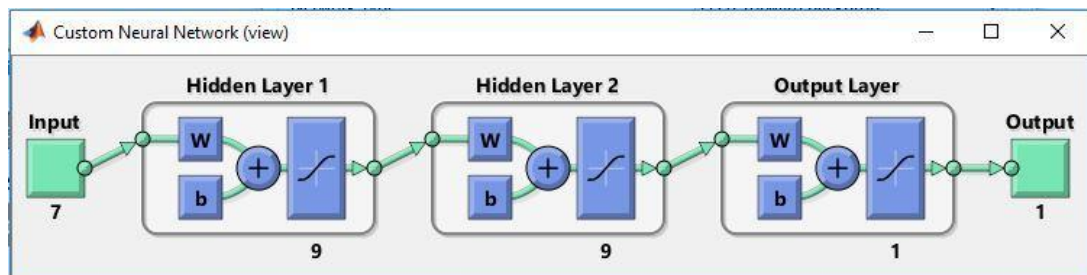
**Función de Entrenamiento:** TRAINLM, la función que renueva los pesos y las ganancias mediante la optimización de Levenberg-Marquardt.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, la función de rendimiento tiene como base en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) – capa de entrada reconocida automáticamente por el MATLAB.

**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 9 neuronas en cada capa oculta y una neurona en la capa de salida.

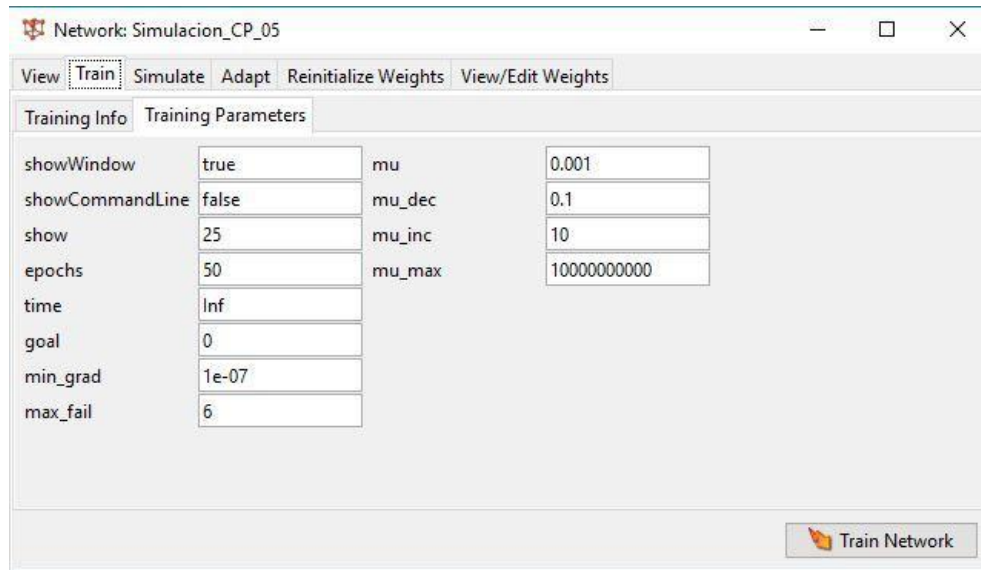


**Figura 24.** Esquema de la red neuronal Simulador\_CP\_05

*Fuente:* elaboración propia

**Propiedades de las capas:** Las capas utilizan la función Tansig, función de transferencia sigmoidea tangente e hiperbólica.

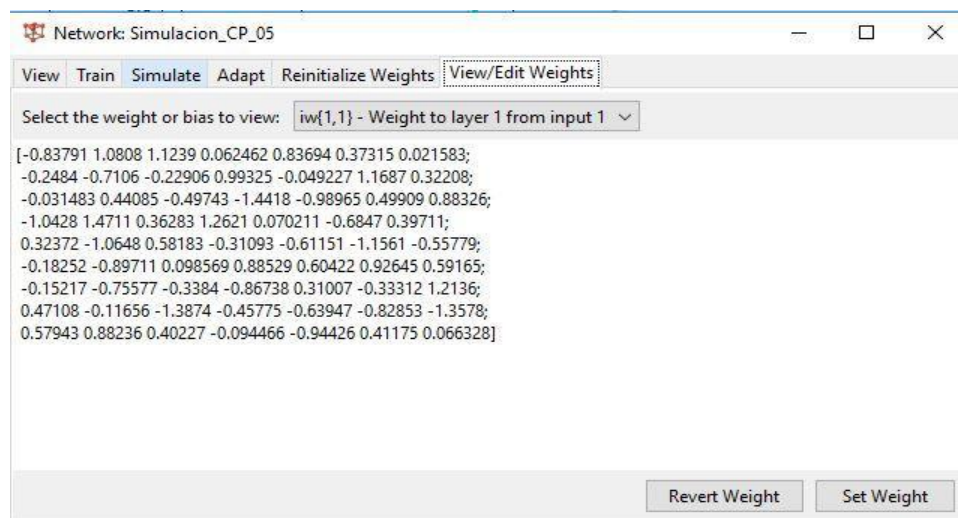
**Parámetros:** Los parámetros de la RNA se muestran en la ventana nntool.



**Figura 25.** Parámetros solicitados por la RNA Simulador\_CP\_05

*Fuente:* elaboración propia

**Configuración de pesos:** Los pesos hallados de la red se muestran en la ventana Neural Networks.



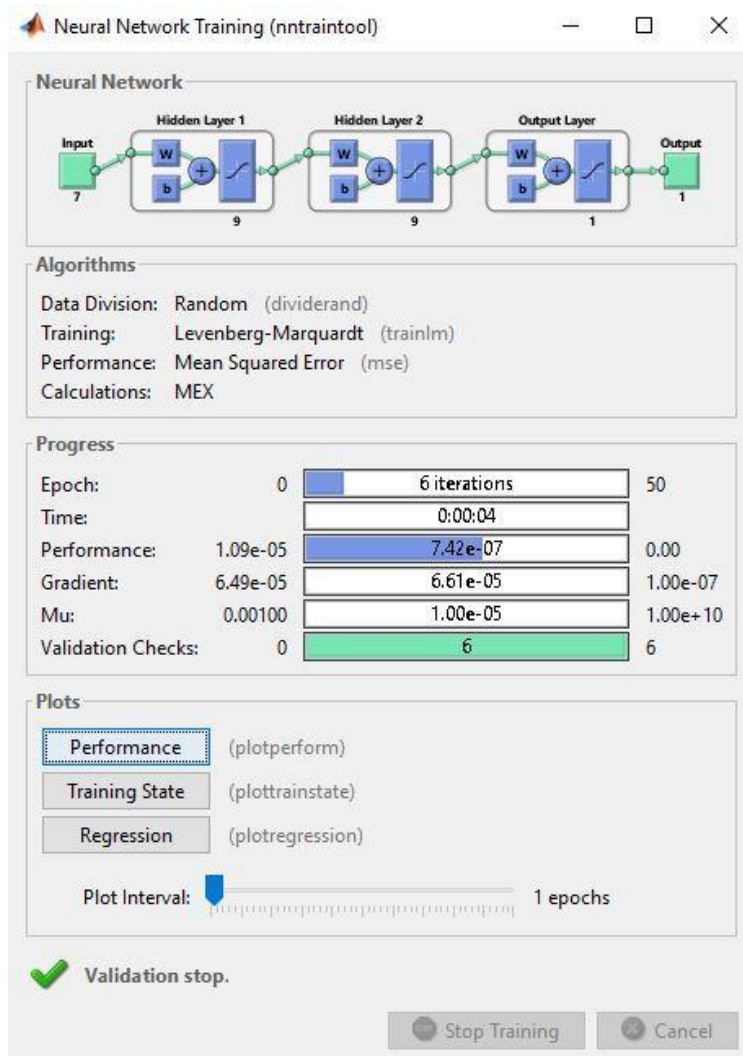
**Figura 26.** Pesos de la RNA Simulador\_CP\_05

*Fuente:* elaboración propia

### c) Resultado

El resultado mostrado en el entrenamiento es el performance que usa la función del error cuadrático medio que se muestra a continuación

Error → 0.0000109



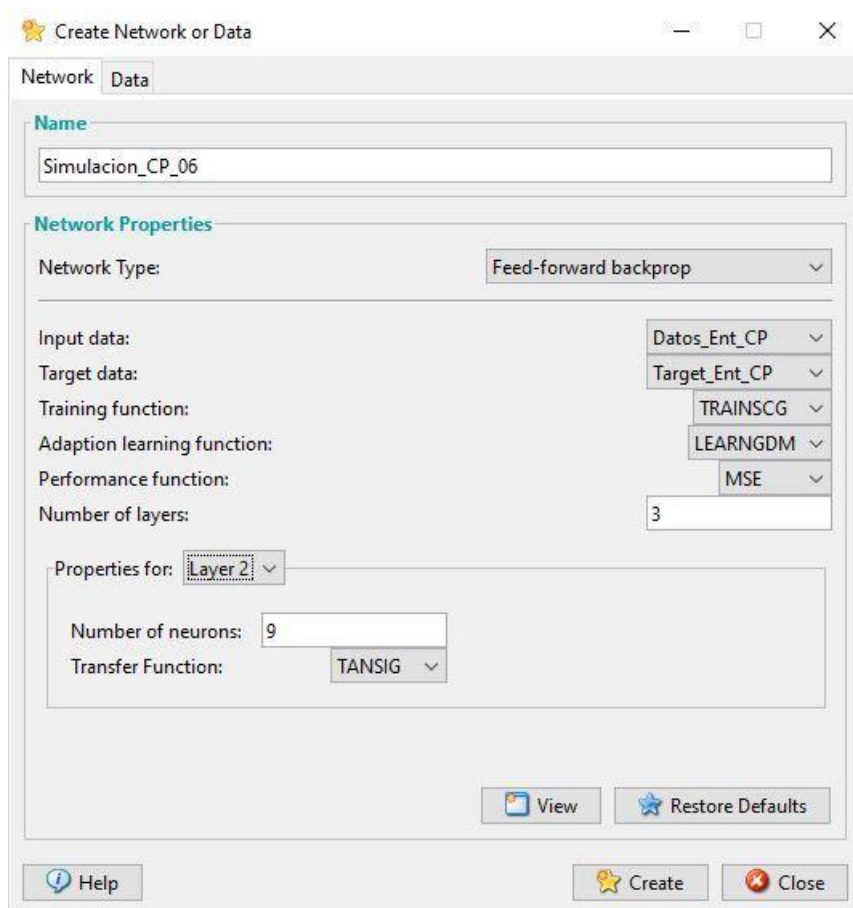
**Figura 27.** Entrenamiento realizado por la red Simulador\_Cp\_05

*Fuente:* elaboración propia



## Configuración 6

**SIMULACION\_CP\_06.** Red Neuronal que muestra su configuración con los parámetros necesarios para su creación en la ventana del Neural Networks.



**Figura 28.** Configuración de la red Simulador\_Cp\_06

*Fuente:* elaboración propia

### a) Método

El método utilizado se basa en la creación de la RNA backpropagation creada bajo el entorno del Matlab Neural Networks (nntool).

### b) Descripción

La RNA creada muestra la siguiente características:

**Tipo de red:** backpropagation



**Rango de las entradas:** 0 y 1


**Función de Entrenamiento:** TRAINSCG función que renueva los pesos y valores de los bias utilizando el método retropropagación de gradiente conjugado escalado.

**Función de Aprendizaje:** LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.

**Función de Rendimiento:** MSE, la función de rendimiento se basa en el error cuadrado medio.

**Número de capas:** 4 (1 de entrada, 2 ocultas y 1 de salida) capa de entrada reconocida automáticamente por el MATLAB.

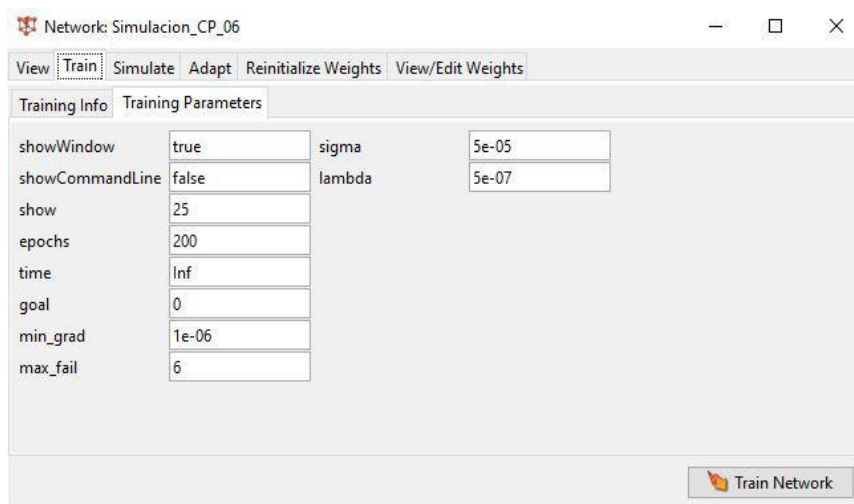
**Número de neuronas por capa:** La primera capa cuenta con 7 neuronas en la capa de entrada, 9 neuronas en cada capa oculta y una neurona en la capa de salida.



**Figura 29.** Esquema de la red neuronal Simulador\_Cp\_06

*Fuente:* elaboración propia

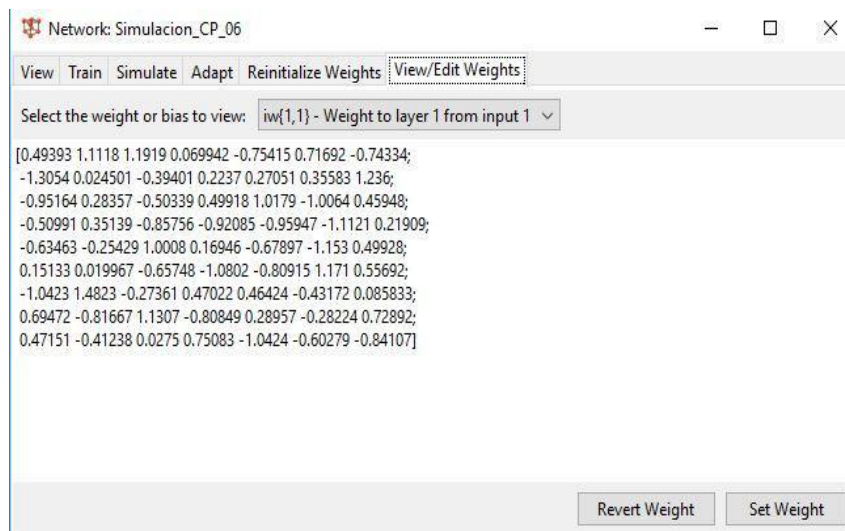
**Propiedades de las capas:** Las capas utilizan la función Tansig, función de transferencia sigmoidea tangente e hiperbólica



**Figura 30.** Configuración de los parámetros solicitados por la red Simulador\_Cp\_06

*Fuente:* elaboración propia

**Configuración de pesos:** Los pesos hallados de la red se muestran en la ventana Neural Networks.



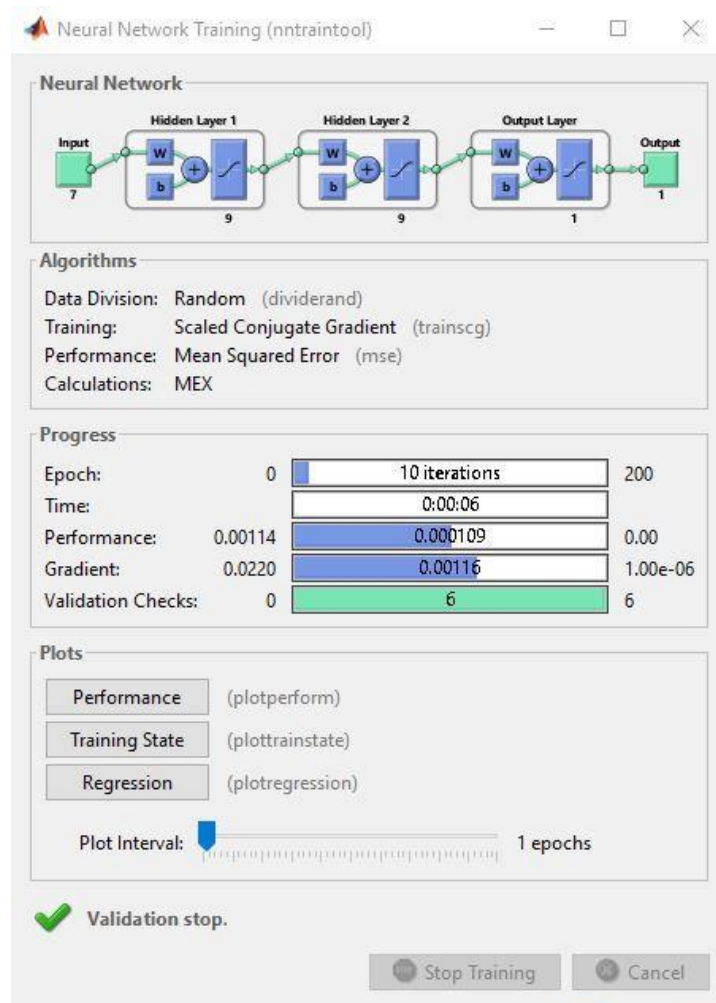
**Figura 31.** Configuración de los pesos de la red Simulador\_Cp\_06

*Fuente:* elaboración propia

**c) Resultado**

El resultado mostrado en el entrenamiento es el performance que usa la función del error cuadrático medio que se muestra a continuación

**Error**→ 0.00114



**Figura 32.** Entrenamiento realizado por la red Simulador\_Cp\_06

Fuente: elaboración propia

## Paso 6: Validación de la RNA

De los datos obtenidos se deduce que las 3 configuraciones más adecuadas son:

Simulacion\_CP\_01, Simulacion\_CP\_04 y el Simulacion\_CP\_05 puesto que estas redes poseen los menores valores de ECM.

**Tabla 6**

*Entrenamiento de la RNAs*

Resultados Obtenidos				
Red Neuronal	Capas ocultas		Épocas	ECM
	Capa 1	Capa 2		
Simulacion_CP_01	5	5	100	0.000635
Simulacion_CP_02	6	6	60	0.00218
Simulacion_CP_03	7	7	100	0.000949
Simulacion_CP_04	7	7	150	0.0000117
Simulacion_CP_05	9	9	50	0.0000109
Simulacion_CP_06	9	9	200	0.00144

*Nota:* Elaboración propia

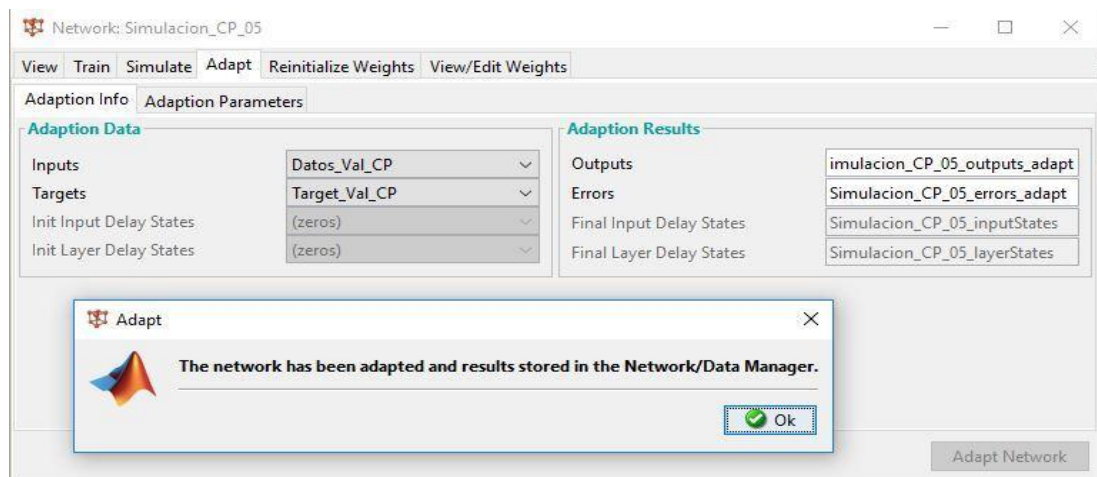
Se muestra el compendio de los resultados obtenidos en las 6 configuraciones de redes, también se muestran los datos más importantes empleados en el entrenamiento de cada red neuronal que referencian al nombre de la red, al número de neuronas por cada capa oculta, luego se muestra el número de épocas realizadas por cada red en su respectivo entrenamiento y el rendimiento o performance equivalente a la función del error cuadrático medio (ECM).

La primera red seleccionada es la red “Simulacion\_CP\_05”, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.0000109, la

segunda es la red “Simulacion\_CP\_04” cuyo valor de ECM es 0.0000117 y la tercera es la red “Simulacion\_CP\_01” que presenta un error de 0.000635. Estas 3 redes serán empleadas para la fase de validación donde a partir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico del costo de parada en la línea trefiladora CP.

El proceso de validación de las redes neuronales seleccionadas que fueron Simulacion\_CP\_05, Simulacion\_CP\_04 y Simulacion\_CP\_01 se realizó utilizando la interfaz Neural Networks (nntool) de la caja de herramientas de MATLAB, cuyo procedimiento, resultado y pruebas se mostrará a continuación.

En la interfaz Neural Networks del MATLAB se cargan las entradas para la validación y las salidas para la misma, se muestra el vector de error de validación, con los errores resultantes.



**Figura 33.** Simulación con los datos de validación para la red Simulacion\_CP\_05

*Fuente:* elaboración propia

### Hallando la tasa de error de las RNAs seleccionadas

La tasa de error será medida utilizando la fórmula del error cuadrático medio para comprobar que el tipo de red seleccionado es el más confiable en la predicción.

$$Ec = \frac{1}{N} \sum_{i=1}^N ||y^i - s^i(w)||^2$$

Donde:

Ec = Error cuadrático.

N = Número de muestras en la validación.

Y i = Salida objetivo de la muestra i.

S i (w) = Salida que se estimada de la RNA para la muestra i

A continuación, en la figura se observan los resultados obtenidos

Simulacion_CP_05				
	Valor Real	Valor Prediccion	Difererencia	ECM
Mar-19	0.9027	0.98900	-0.08627	0.09525
Abr-19	0.2957	0.40566	-0.10996	
May-19	0.5066	0.48531	0.02133	
Jun-19	0.7855	0.91324	-0.12769	
Simulacion_CP_04				
	Valor Real	Valor Prediccion	Difererencia	ECM
Mar-19	0.9027	0.97494	-0.07221	0.13219
Abr-19	0.2957	0.30698	-0.01128	
May-19	0.5066	0.31215	0.19449	
Jun-19	0.7855	0.62206	0.16349	
Simulacion_CP_01				
	Valor Real	Valor Prediccion	Difererencia	ECM
Mar-19	0.9027	0.90459	-0.00186	0.12571
Abr-19	0.2957	0.29559	0.00011	
May-19	0.5066	0.25552	0.25112	
Jun-19	0.7855	0.79748	-0.01193	

**Figura 34.** Se muestra la los resultados de los ECM de las RNA.

*Fuente:* elaboración propia

A continuación, se muestran las RNAs validadas, siendo la red Simulacion\_CP\_05 que genera el menor ECM.

**Tabla 7**

*Comparativo de los ECM de las configuraciones de las RNAs*

<b>Resultados Obtenidos para costo de parada CP</b>			
Red Neuronal	Capas Ocultas		ECM
	Capa 1	Capa 2	
Simulacion_CP_05	9	9	0.09525
Simulacion_CP_04	7	7	0.13219
Simulacion_CP_01	5	5	0.12571

*Nota:* Elaboración propia

**Paso 7: Selección de la RNA más exacta para el Pronóstico de CP**

Se analizó las RNAs, de los cuales se tomó como modelo la red Simulacion\_CP\_05 por presentar el menor ECM, con el cual se realizar el pronóstico de los meses marzo, abril, mayo y junio del 2019 para el costo de parada de línea trefiladora A120.

Variables - Simulacion\_CP\_05\_outputs\_adapt{1, 1}

Simulacion\_CP\_05\_outputs\_adapt

Simulacion\_CP\_05\_outputs\_adapt{1, 1}

Simulacion\_CP\_05\_outputs\_adapt{1, 1}

1	2	3	4	5	6
0.9890	0.4057	0.4853	0.9132		

**Figura 35.** RNA seleccionada para el pronóstico del costo de parada de línea A120

*Fuente:* elaboración propia

## Paso 8: Datos pronosticados por la RNA seleccionada

Como los datos pronosticados se muestran normalizados, se tiene que convertirlos a sus valores normales para después realizar la comparación con los datos reales.

Proceso de conversión de los datos normalizados, se multiplica el máximo valor de costos de parada real por el dato normalizado, resultando el valor original, de la misma manera con los datos resultante del pronóstico de la RNA.

Para la conversión del mes de marzo 2019 el costo de parada de línea real es:

$$\text{Costo de las horas de parada de línea(convertido)} = S/57,640.934 * 0.9027 = S/ 52,034.453$$

Para la conversión del mes de marzo 2019 el costo de parada de línea pronosticada por la RNA es:

$$\text{Costo de las horas de parada pronosticado (convertido)} = S/57,640.934 * 0.98900 = S/ 57,006.884$$

**Tabla 8**

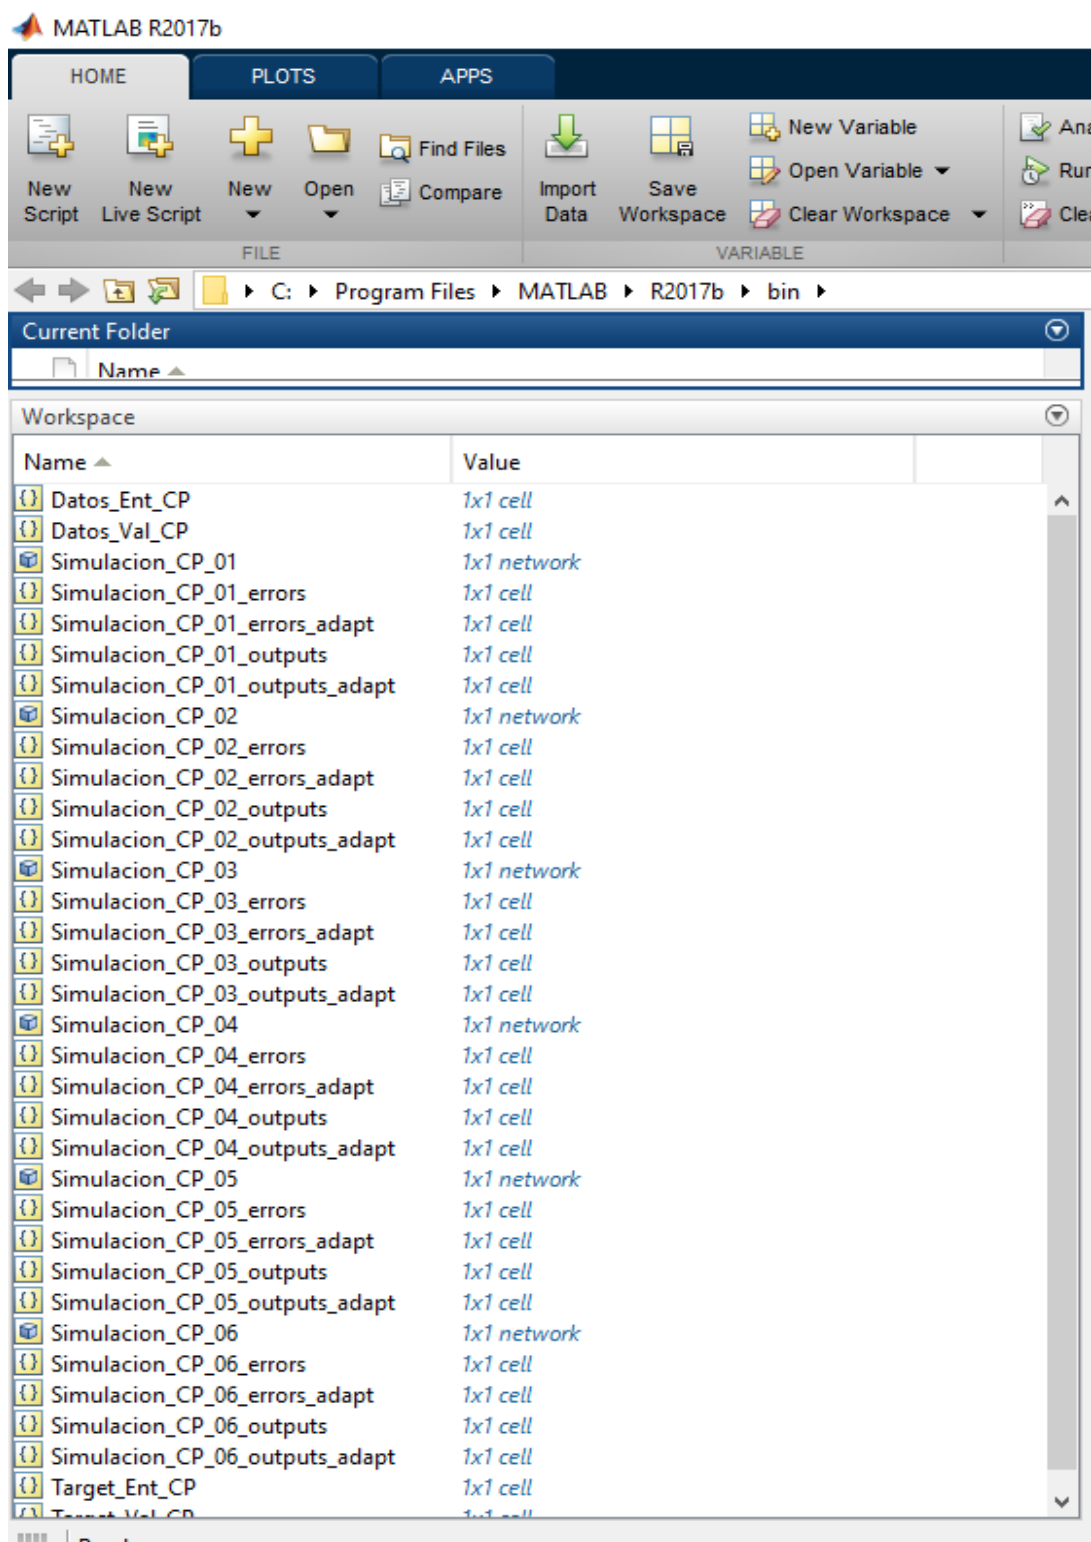
*Costos de parada pronosticado*

Máximo valor	Yi			
	Costo de las horas paradas (normalizado)	Costo de las horas de parada de línea(convertido)	Costo de las horas de parada de línea pronosticado (normalizado)	Costo de las horas de parada pronosticado (convertido)
Mar-2019	<b>0.9027</b>	S/ 52,034.453	0.98900	S/ 57,006.884
Abr-2019	<b>0.2957</b>	S/ 17,044.604	0.40566	S/ 23,382.621
May-2019	<b>0.5066</b>	S/ 29,203.239	0.48531	S/ 27,973.722
Jun-2019	<b>0.7855</b>	S/ 45,279.656	0.91324	S/ 52,640.007

*Nota:* Elaboración propia

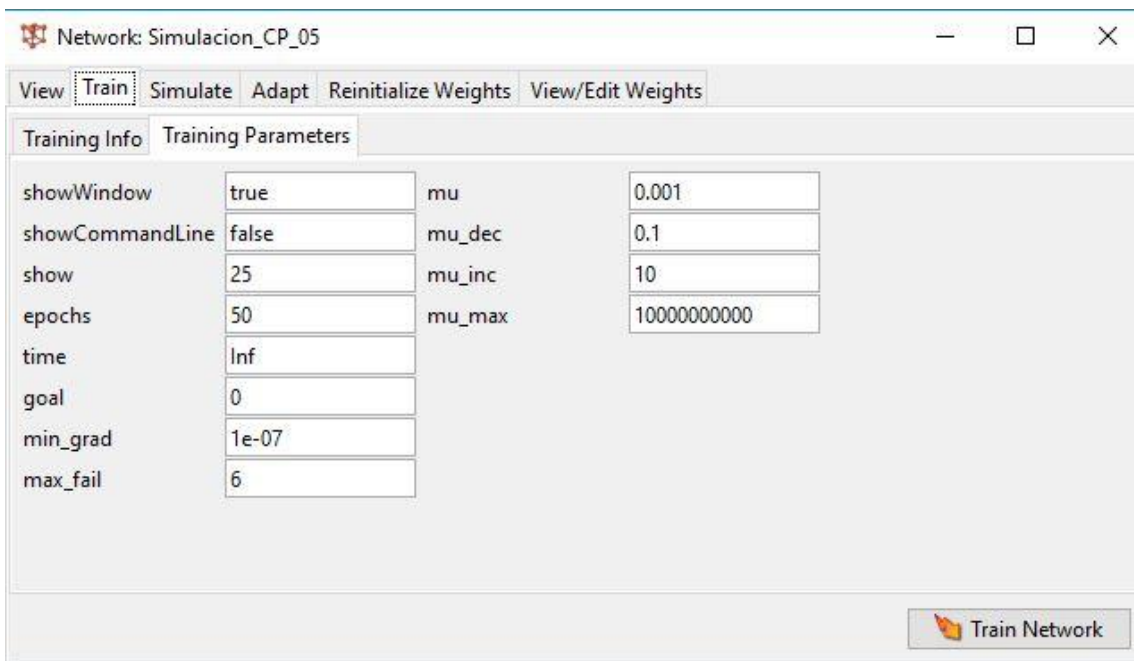


## Anexo 7. Configuración de las 6 RNA para el pronóstico de costo de parada



Fuente: Elaboración propia

## Anexo 8. Configuración de la red seleccionada para el pronóstico

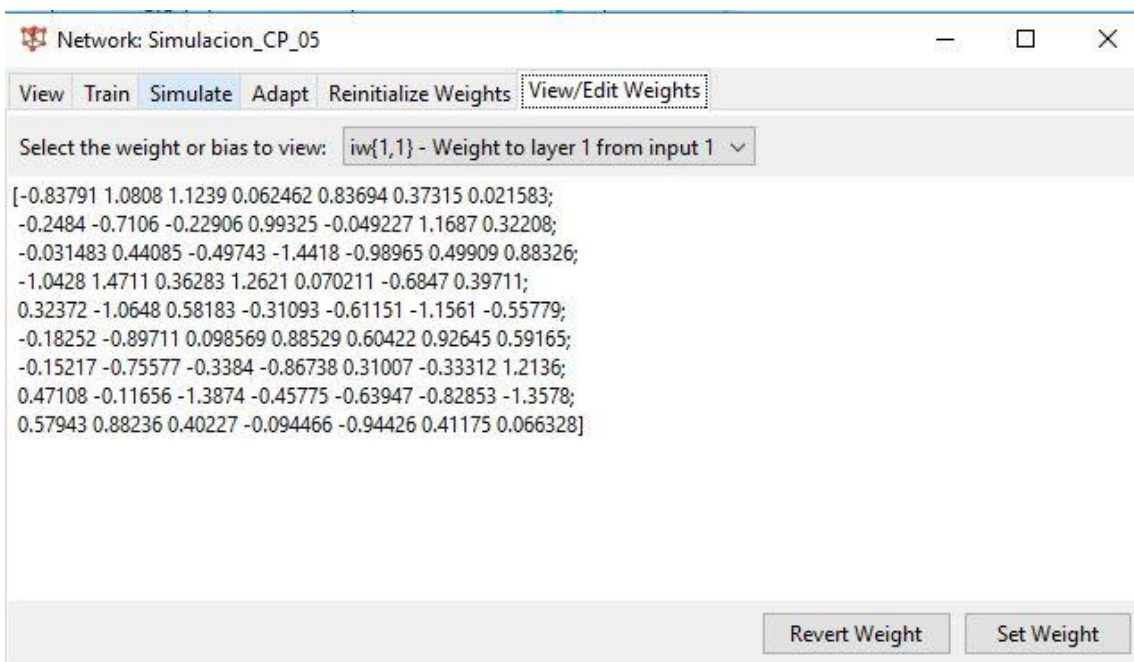


The screenshot shows the 'Network: Simulacion\_CP\_05' window with the 'Train' tab selected. The 'Training Parameters' section contains the following settings:

showWindow	true	mu	0.001
showCommandLine	false	mu_dec	0.1
show	25	mu_inc	10
epochs	50	mu_max	10000000000
time	Inf		
goal	0		
min_grad	1e-07		
max_fail	6		

A 'Train Network' button is located at the bottom right of the window.

Fuente: Elaboración Propia



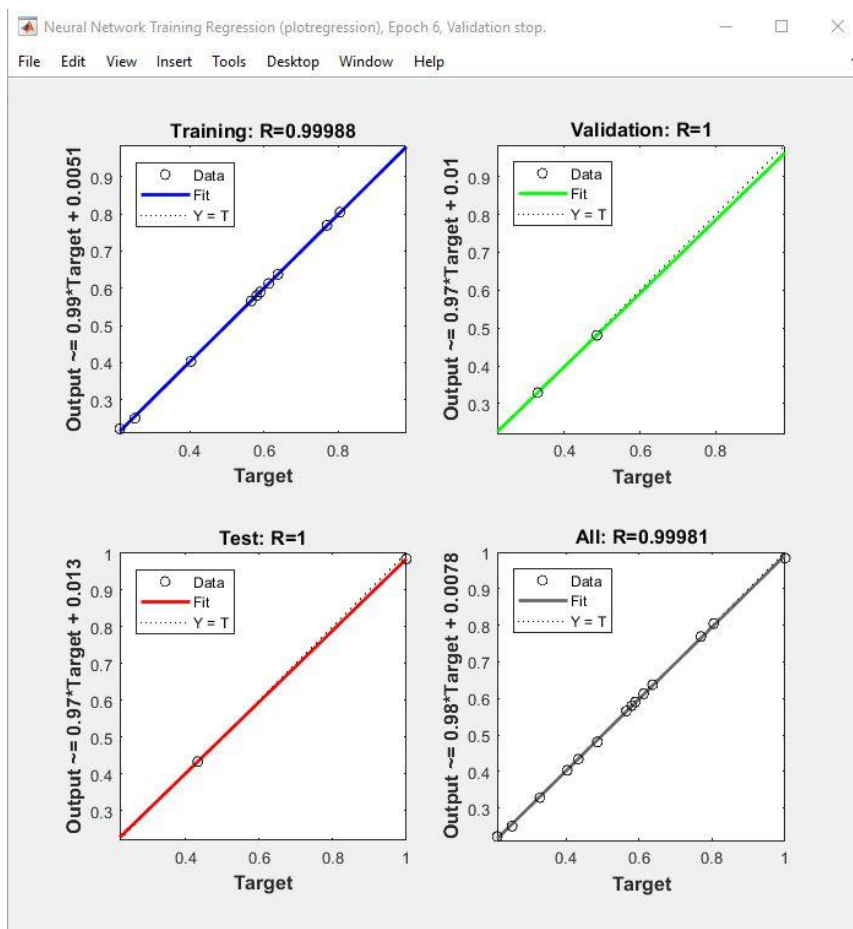
The screenshot shows the 'Network: Simulacion\_CP\_05' window with the 'View/Edit Weights' tab selected. The 'Select the weight or bias to view:' dropdown is set to 'iw{1,1} - Weight to layer 1 from input 1'. The displayed weights are:

```
[-0.83791 1.0808 1.1239 0.062462 0.83694 0.37315 0.021583;  
-0.2484 -0.7106 -0.22906 0.99325 -0.049227 1.1687 0.32208;  
-0.031483 0.44085 -0.49743 -1.4418 -0.98965 0.49909 0.88326;  
-1.0428 1.4711 0.36283 1.2621 0.070211 -0.6847 0.39711;  
0.32372 -1.0648 0.58183 -0.31093 -0.61151 -1.1561 -0.55779;  
-0.18252 -0.89711 0.098569 0.88529 0.60422 0.92645 0.59165;  
-0.15217 -0.75577 -0.3384 -0.86738 0.31007 -0.33312 1.2136;  
0.47108 -0.11656 -1.3874 -0.45775 -0.63947 -0.82853 -1.3578;  
0.57943 0.88236 0.40227 -0.094466 -0.94426 0.41175 0.066328]
```

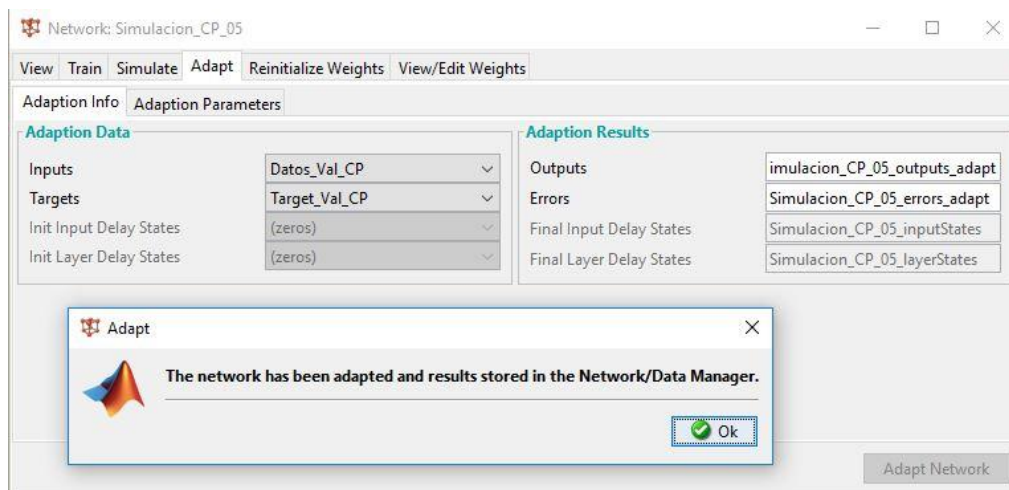
'Revert Weight' and 'Set Weight' buttons are located at the bottom right.

Fuente: Elaboración Propia

## Anexo 9. Regresión lineal resultante de la RNA seleccionada para el pronóstico



Fuente: Elaboración propia.



Fuente: Elaboración propia.

**Anexo 10.** Evidencias fotográficas mantenimiento deficiente



Fuente: Empresa en estudio



Fuente: Empresa en estudio